



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CENTRO DE CIÊNCIAS**  
**DEPARTAMENTO DE COMPUTAÇÃO**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO**

**AMANDA DRIELLY PIRES VENCESLAU**

**SEACT: MÉTODO HÍBRIDO DE SEGMENTAÇÃO DE FLUXOS DE DADOS DE  
SENSORES PARA AMBIENTES DE VIDA ASSISTIDA**

**FORTALEZA**

**2023**

AMANDA DRIELLY PIRES VENCESLAU

SEACT: MÉTODO HÍBRIDO DE SEGMENTAÇÃO DE FLUXOS DE DADOS DE  
SENSORES PARA AMBIENTES DE VIDA ASSISTIDA

Tese apresentada ao Programa de Pós-Graduação em Ciência da Computação do Centro de Ciências da Universidade Federal do Ceará, como requisito parcial à obtenção do título de doutora em Ciência da Computação. Área de Concentração: Bancos de Dados

Orientadora: Prof<sup>a</sup>. Dr<sup>a</sup>. Vânia Maria Ponte Vidal

Coorientadora: Prof<sup>a</sup>. Dr<sup>a</sup>. Rossana Maria de Castro Andrade

FORTALEZA

2023

Dados Internacionais de Catalogação na Publicação  
Universidade Federal do Ceará  
Sistema de Bibliotecas  
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

---

V562s Venceslau, Amanda Drielly Pires.

SeAct: Método Híbrido de Segmentação de Fluxos de Dados de Sensores para Ambientes de Vida Assistida / Amanda Drielly Pires Venceslau. – 2023.  
120 f. : il. color.

Tese (doutorado) – Universidade Federal do Ceará, Centro de Ciências, Programa de Pós-Graduação em Ciência da Computação, Fortaleza, 2023.

Orientação: Prof. Dr. Vânia Maria Ponte Vidal.

Coorientação: Prof. Dr. Rossana Maria de Castro Andrade.

1. Segmentação de Dados de Sensores. 2. Método Híbrido de Segmentação de Dados. 3. Inferência Semântica. 4. Aprendizado de Máquina. 5. Reconhecimento de Atividade Humana. I. Título.

CDD 005

---

AMANDA DRIELLY PIRES VENCESLAU

SEACT: MÉTODO HÍBRIDO DE SEGMENTAÇÃO DE FLUXOS DE DADOS DE  
SENSORES PARA AMBIENTES DE VIDA ASSISTIDA

Tese apresentada ao Programa de Pós-Graduação em Ciência da Computação do Centro de Ciências da Universidade Federal do Ceará, como requisito parcial à obtenção do título de doutora em Ciência da Computação. Área de Concentração: Bancos de Dados

Aprovada em: 15/06/2023

BANCA EXAMINADORA

---

Prof<sup>ª</sup>. Dr<sup>ª</sup>. Vânia Maria Ponte Vidal (Orientadora)  
Universidade Federal do Ceará (UFC)

---

Prof<sup>ª</sup>. Dr<sup>ª</sup>. Rossana Maria de Castro Andrade (Coorientadora)  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. José Maria da Silva Monteiro Filho  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Tales Paiva Nogueira  
Universidade da Integração Internacional da Lusofonia  
Afro-Brasileira (UNILAB)

---

Prof<sup>ª</sup>. Dr<sup>ª</sup>. Thais Vasconcelos Batista  
Universidade Federal do Rio Grande do Norte (UFRN)

---

Prof<sup>ª</sup>. Dr<sup>ª</sup>. Chiara Renso  
Consiglio Nazionale delle Ricerche (CNR-Italy)

A Deus, por cuidar sempre de mim.

## AGRADECIMENTOS

Primeiramente, gostaria de agradecer a Deus por me sustentar até aqui. Obrigada Deus, pela sabedoria durante essa longa jornada.

Aos meus pais, Erinaldo Pires Correia e Doracy de Souza Pires, e os meus irmãos, Bruno e Carla. Obrigado por compartilhar esse sonho. Agradeço imensamente todo esforço e sacrifício imensurável que vocês fizeram para torná-lo realidade. Ao meu esposo Radams pelo apoio e incentivo durante todos esses anos. Aos meus filhos, filhos do doutorado, Gustavo e Gabriel, que me fizeram renascer para vida e para esse sonho. Vocês são parte desse sonho. Agradeço também a minha avó, todos tios, tias, primos e primas que me incentivaram durante esse período.

À minha orientadora Prof<sup>a</sup>. Vânia Vidal. Agradeço pela paciência, orientação e assistência, essencial para a realização deste trabalho. Aprendi muito ao longo dos anos.

Agradeço à minha co-orientadora Prof<sup>a</sup>. Rossana Andrade que gentilmente aceitou o convite e me acolheu no seu laboratório. Muito obrigada pela disponibilidade, incentivo, ensinamentos e oportunidades.

Aos meus amigos e parceiros de pesquisa, Prof. Gilvan Maia, Prof. Wellington Franco e Narciso Arruda por todo apoio e colaboração no meu trabalho de doutorado.

Aos amigos do laboratório ARIDa, por sempre estarem prontos para ajudar em qualquer dificuldade. Dentre eles, destaco os amigos: Tiago Vinnuto, Arlino Magalhães, Matheus Mayron, Salomão Santos, Gustavo Moraes, Bruno e Gabriel pelo o apoio durante o doutorado. As amigas Ticiane Linhares, Lívia Almada e ao amigo Régis, pelo apoio.

Aos amigos e amigas do laboratório GREat. Obrigado pela acolhida, pelos momentos divertidos e pelo apoio nos momentos difíceis. Em especial destaco: Evilásio Júnior, Pedro Almir, Rainara Carvalho, Ismayle Santos, Rute Castro, Amanda Sousa e Joseane Vale.

Aos amigos e amigas da Universidade Federal do Ceará em Crateús pela oportunidade do afastamento para me dedicar ao doutorado. Especialmente, Lisieux Andrade, Rennan Dantas, André Meireles, Emerson Barros, Marciel Barros e Allyson Araújo.

Finalmente, gostaria de agradecer à minha banca de tese, Prof<sup>a</sup>. Dr<sup>a</sup> Vânia Vidal, Profa. Dr<sup>a</sup>. Rossana Andrade, Prof. Dr. José Maria Monteiro, Prof. Dr. Tales Nogueira, Profa. Dr<sup>a</sup>. Thais Batista e Dr<sup>a</sup>. Chiara Renso, por todas as considerações que enriqueceram esta tese. Agradecer ao Prof. Dr. Angelo Brayner pelas considerações valiosas a proposta desta tese.

“O otimista é um tolo. O pessimista, um chato.  
Bom mesmo é ser um realista esperançoso.”

(Ariano Suassuna)

## RESUMO

O envelhecimento da população em todo o mundo demanda ferramentas avançadas para monitorar continuamente as atividades das pessoas, apoiando o envelhecimento e detectando possíveis problemas de saúde. Um Ambiente de Vida Assistida – *Ambient Assisted Living*, do inglês – incorpora e integra objetos e pessoas de maneira não intrusiva e discreta, com soluções que tratam desde a coleta dos fluxos de dados de sensores até a análise dos dados para tomada de decisão. Uma das principais limitações dos (AAL) reside no fato de que os fluxos de dados necessitam ser constantemente monitorados por meio de janelas de tempo, ou segmentos, cujas dimensões devem ser ajustadas conforme as ações que denotam atividades em andamento. Entretanto, um segmento pode não conter eventos relevantes para uma ação atual, dificultando sua análise. Nesse contexto, um problema crescente na segmentação de dados de sensores está relacionado à captura de eventos que podem ser gerados pelo mesmo sensor, porém pertencentes a atividades diferentes, gerando ambiguidade. Para solucionar esse problema, a literatura aborda diferentes métodos que aprendem o padrão de atividades de um residente de AAL, mas não combinam ou processam os eventos gerados pelos sensores semanticamente para reconhecer atividades. Além disso, não existem recursos que permitam a anotação, consulta ou rastreamento dos resultados do processo de segmentação, dificultando a análise dos segmentos oriundos de recursos heterogêneos, sejam sensores ou técnicas aplicadas na segmentação. Esse trabalho propõe um método híbrido de segmentação de fluxos de dados de sensores para AAL, denominado SeAct. A ontologia SeRt para anotação semântica de segmentos também é apresentada. Três experimentos foram realizados para avaliar o método proposto, adotando dois conjuntos de dados públicos. Como resultado, melhorias na acurácia e precisão do reconhecimento de atividade humana foram identificadas em relação à abordagens existentes. Além disso, foram aplicadas Questões de Competência para validar a SeRt.

**Palavras-chave:** segmentação de dados de sensores; método híbrido de segmentação de dados; inferência semântica; aprendizado de máquina; reconhecimento de atividade humana.

## ABSTRACT

Population aging worldwide demands advanced tools to continuously monitor people's activities, supporting aging and detecting potential health issues. Ambient Assisted Living (AAL) incorporates and integrates objects and people in a non-intrusive and discreet way, with solutions that deal with everything from the collection of data streams from sensors to the analysis of data for decision-making. One of the main limitations of AAL resides in the fact that data flows need to be constantly monitored through time windows or segments, whose dimensions must be adjusted according to the actions that denote ongoing activities. However, a segment may not contain events relevant to the current action, making its analysis difficult. In this context, a growing problem in sensor data segmentation is related to capturing events that the same sensor can generate, but belonging to different activities, generating ambiguity. To solve this problem, the literature addresses different methods that learn the activity pattern of an AAL resident but do not combine or process the events generated by the sensors semantically to recognize activities. In addition, no resources allow the annotation, query, or tracking of the results of the segmentation process, making it challenging to analyze segments from heterogeneous resources, whether sensors or techniques applied in segmentation. This work proposes a hybrid method for segmenting sensor data streams for AAL, called SeAct. The SeRt ontology for segments semantic annotation is also presented. Three experiments were conducted to evaluate the proposed method, adopting two public datasets. As a result, improvements in the accuracy and precision of human activity recognition were identified over existing approaches. In addition, Competence Questions were applied to validate the SeRt.

**Keywords:** sensor data segmentation; hybrid data segmentation method; semantic inference; machine learning; human activity recognition.

## LISTA DE FIGURAS

Figura 1 – Componentes de um Ambiente de Vida Assistida . . . . .	15
Figura 2 – Arquitetura de AAL para aplicações de tomada de decisão . . . . .	26
Figura 3 – Classificação de atividades com janela deslizante estática . . . . .	27
Figura 4 – O processo de mapeamento sistemático . . . . .	31
Figura 5 – Propriedades de relacionamento semântico entre objetos do cotidiano, conjunto de ações para AVD FazerChá e características do sensor. . . . .	38
Figura 6 – Visão geral da abordagem de segmentação habilitada semanticamente para raciocínio com Base de Conhecimento genérica (T-box) e de preferências (A-box). . . . .	39
Figura 7 – Visão de alto nível de CEP. . . . .	41
Figura 8 – Arquitetura SEON . . . . .	43
Figura 9 – Arquitetura funcional. . . . .	45
Figura 10 – Visão geral da abordagem de segmentação habilitada semanticamente para raciocínio com Base de Conhecimento genérica (T-box) e de preferências (A-box). . . . .	46
Figura 11 – IoT-lite Ontology . . . . .	51
Figura 12 – SSN Ontology . . . . .	51
Figura 13 – SAO (Stream Annotation Ontology) . . . . .	52
Figura 14 – Classes e propriedades IoT-Stream . . . . .	52
Figura 15 – O grafo das coisas: Arquitetura em camadas . . . . .	53
Figura 16 – Classes e propriedades SeRt . . . . .	56
Figura 17 – SeRt e o reuso das principais ontologias. . . . .	57
Figura 18 – Processo de anotação adotando SeRt. . . . .	58
Figura 19 – Exemplo de anotação adotando SeRt para técnica baseada em dados. . . . .	59
Figura 20 – Exemplo de anotação adotando SeRt para técnica baseada em conhecimento. . . . .	59
Figura 21 – Exemplo de anotação adotando SeRt para técnica híbrida. . . . .	60
Figura 22 – Visão geral do SeAct integrado a um AAL. . . . .	65
Figura 23 – SeAct aplicado a uma infraestrutura IoT. . . . .	66
Figura 24 – Arquitetura SeAct. . . . .	67
Figura 25 – Fluxo de trabalho da subetapa de aquisição do conjunto de dados de sensores. . . . .	69
Figura 26 – Amostras de imagens RGB do conjunto de dados CAD-120. . . . .	70

Figura 27 – Matriz de dispersão para usuários do conjuntos de dados CAD-120. . . . .	71
Figura 28 – Fluxo de trabalho da subetapa de classificação . . . . .	73
Figura 29 – Ontologia ActiOn com instâncias. . . . .	76
Figura 30 – Fluxo de trabalho da subetapa de regras de inferência semântica . . . . .	78
Figura 31 – Fluxo de trabalho da subetapa de operador de janela . . . . .	81
Figura 32 – Instância da arquitetura SeAct. . . . .	82
Figura 33 – Fluxo de trabalho da subetapa de anotação . . . . .	84
Figura 34 – Exemplo motivador SeRt. . . . .	85
Figura 35 – Matriz de confusão SeAct para atividades no conjunto de dados CAD-120. .	95
Figura 36 – Matriz de confusão de Díaz-Rodríguez <i>et al.</i> (2014) para atividades no conjunto de dados CAD-120. . . . .	95

## LISTA DE ALGORITMOS

Algoritmo 1 – Algoritmo para Construção de Regras . . . . .	78
Algoritmo 2 – Algoritmo Operador de Janela . . . . .	82

## LISTA DE TABELAS

Tabela 1 – Lista dos tipos de sensores mais comuns em casas inteligentes . . . . .	25
Tabela 2 – Técnicas de segmentação de fluxos de dados de sensores aplicadas ao Reconhecimento de Atividade Humana . . . . .	33
Tabela 3 – Métodos de segmentação de fluxos de dados de sensores aplicados ao Reconhecimento de Atividade Humana . . . . .	33
Tabela 4 – Técnicas híbridas de segmentação de fluxos dados de sensores para reconhecimento de atividade humana. As colunas adotam: TS — Tecnologia Semântica; e OS — Ontologia de Segmentação. As linhas adotam: Dado de Sensor Bruto (DSB), AP — Aprendizagem Probabilística, ODU — Objeto De Uso; PH — Postura Humana; L — Localização; Otimização Sequencial Mínima (SMO)- Otimização Sequencial Mínima; PV - Perceptron Votado; FA - Florestas Aleatórias; e TD - Tabela de Decisão. . . . .	49
Tabela 5 – Análise comparativa de ontologias para anotação de fluxos de dados de sensores	53
Tabela 6 – Descrição semântica das atividades utilizadas no estudo de caso. . . . .	74
Tabela 7 – Exemplo de Regra de Inferência em SeAct. . . . .	79
Tabela 8 – Questões de Competência para a ontologia SeRt . . . . .	88
Tabela 9 – Exemplo de consultas para Questões de Competência em SeRt . . . . .	89
Tabela 10 – Comparação da abordagem para o reconhecimento de atividades usando o conjunto de dados CAD-120. . . . .	94
Tabela 11 – Eventos do sensor por atividade no conjunto de dados Kasteren. . . . .	98
Tabela 12 – Comparação de abordagens que utilizam o Kasteren. . . . .	101
Tabela 13 – Publicações decorrentes da tese. . . . .	107
Tabela 14 – Publicações decorrentes da tese. . . . .	107
Tabela 15 – Regras de Inferência em SeAct. . . . .	119

## LISTA DE ABREVIATURAS E SIGLAS

DSB	Dado de Sensor Bruto
SMO	Otimização Sequencial Mínima
IoT	Internet das Coisas
AAL	<i>Ambient Assisted Living</i>
AVD	Atividade da Vida Diária
RAH	Reconhecimento de Atividade Humana
CASAS	<i>Center for Advanced Studies in Adaptive Systems</i>
SECURE	Sistema Inteligente de Diagnóstico Antecipado e Acompanhamento Domiciliar
FSCEP	<i>Fuzzy Semantic Complex Event Processing</i>
MLN	<i>Markov Logic Network</i>
LD	Lógica de Descrição
PMC	<i>Pearson Product Moment Correlation</i>
LCS	<i>Least Common Subsumer</i>
CEP	<i>Complex Event Processing</i>
EC	Eventos Complexos
W3C	<i>World Wide Web Consortium</i>
SWRL	<i>Semantic Web Rule Language</i>
k-NN	<i>K-Nearest Neighbors</i>
LoCCAM	<i>Loosely Coupled Context Acquisition Middleware</i>
KG	<i>Knowledge Graph</i>
CAD	<i>Cornell Activity Dataset</i>
AVC	Acidente Vascular Cerebral
AM	Aprendizado de Máquina
RDF	<i>Resource Description Framework</i>
OWL	<i>Ontology Web Language</i>
API	<i>Application Programming Interface</i>
SPARQL	<i>SPARQL Protocol and RDF Query Language</i>

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>14</b>
<b>1.1</b>	<b>Contextualização</b>	<b>14</b>
<b>1.2</b>	<b>Motivação</b>	<b>17</b>
<b>1.3</b>	<b>Hipótese, Objetivo e Questões de pesquisa</b>	<b>20</b>
<b>1.4</b>	<b>Metodologia e Resultados Esperados</b>	<b>21</b>
<b>1.5</b>	<b>Organização da tese</b>	<b>22</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>24</b>
<b>2.1</b>	<b>Ambientes de Vida Assistida</b>	<b>24</b>
<b>2.1.1</b>	<i>Aquisição de Dados e Processamento</i>	<b>25</b>
<b>2.1.2</b>	<i>Análise de Dados</i>	<b>27</b>
<b>2.1.3</b>	<i>Reconhecimento de Atividade Humana</i>	<b>28</b>
<b>2.2</b>	<b>Técnicas de Segmentação de Fluxos de Dados</b>	<b>30</b>
<b>2.2.1</b>	<i>Baseadas em Métricas</i>	<b>34</b>
<b>2.2.2</b>	<i>Baseadas em Dados</i>	<b>34</b>
<b>2.2.3</b>	<i>Baseadas em Conhecimento</i>	<b>36</b>
<b>2.2.4</b>	<i>Híbridas</i>	<b>39</b>
<b>2.3</b>	<b>Processamento de Eventos Complexos</b>	<b>40</b>
<b>2.4</b>	<b>Ontologia</b>	<b>42</b>
<b>2.5</b>	<b>Considerações Finais</b>	<b>44</b>
<b>3</b>	<b>TRABALHOS RELACIONADOS</b>	<b>45</b>
<b>3.1</b>	<b>Técnicas Híbridas de Segmentação de Fluxos de Dados</b>	<b>45</b>
<b>3.2</b>	<b>Ontologias para Anotação Semântica de Fluxos de Dados</b>	<b>50</b>
<b>4</b>	<b>SERT: ONTOLOGIA PARA ANOTAÇÃO DE SEGMENTOS</b>	<b>55</b>
<b>4.1</b>	<b>Classes e Propriedades da ontologia SeRt</b>	<b>55</b>
<b>4.2</b>	<b>Processo de Anotação usando SeRt</b>	<b>57</b>
<b>4.3</b>	<b>Exemplos de Anotação de Segmentos usando SeRt</b>	<b>58</b>
<b>4.4</b>	<b>Considerações Finais</b>	<b>60</b>
<b>5</b>	<b>SEACT: MÉTODO HÍBRIDO DE SEGMENTAÇÃO DE FLUXOS DE DADOS DE SENSORES</b>	<b>62</b>
<b>5.1</b>	<b>Visão geral</b>	<b>62</b>

5.2	<b>Camadas e Arquitetura</b>	65
5.3	<b>Etapa <i>Offline</i></b>	67
5.3.1	<i>Aquisição do Conjunto de Dados de Sensores</i>	68
5.3.2	<i>Classificação</i>	71
5.3.3	<i>Ontologia ActiOn</i>	75
5.3.4	<i>Regras de Inferência Semântica</i>	76
5.4	<b>Etapa <i>Online</i></b>	80
5.4.1	<i>Operador de Janela</i>	80
5.4.2	<i>Anotação</i>	83
5.5	<b>Considerações Finais</b>	85
6	<b>AVALIAÇÃO</b>	87
6.1	<b>Validação da Ontologia SeRt</b>	87
6.2	<b>Experimentos com o Método SeAct</b>	90
6.2.1	<i>Conjunto de Dados CAD-120</i>	90
6.2.2	<i>Conjunto de Dados Kasteren</i>	96
6.2.2.1	<i>Resultados da segmentação adotando janela estática</i>	96
6.2.2.2	<i>Resultados da segmentação adotando janela dinâmica</i>	99
6.2.3	<i>Ameaças à Validade</i>	102
7	<b>CONCLUSÃO</b>	103
7.1	<b>Um breve resumo</b>	103
7.2	<b>Revisitando as Questões de Pesquisa</b>	103
7.3	<b>Contribuições e Limitações do Trabalho</b>	105
7.4	<b>Publicações</b>	106
7.5	<b>Trabalhos Futuros</b>	108
	<b>REFERÊNCIAS</b>	110
	<b>APÊNDICE A – REGRAS DE INFERÊNCIA</b>	119

# 1 INTRODUÇÃO

Esta tese apresenta um método de segmentação semântica em Ambientes de Vida Assistida (AAL - *Ambient Assisted Living*, do inglês). Tal método envolve processamento de dados em AAL e propõe o uso de técnicas de segmentação de fluxos de dados de sensores, particularmente, técnicas híbridas.

O presente capítulo está organizado da seguinte forma. A Seção 1.1 descreve a contextualização, enquanto a Seção 1.2 apresenta a motivação deste trabalho e o problema abordado. Na Seção 1.3 são definidas hipóteses e questões de pesquisa. A seguir, a seção 1.4 apresenta as principais contribuições. Por fim, a Seção 1.6 apresenta a organização desta tese.

## 1.1 Contextualização

Segundo o relatório (ECONOMIC; AFFAIRS POPULATION DIVISION, 2019), o número de pessoas acima dos 80 anos triplicará de 143 milhões em 2019 para 426 milhões em 2050. Assim, é razoável assumir que o significativo aumento da população idosa motiva o desenvolvimento de ferramentas avançadas para monitorar continuamente pessoas, apoiando seu envelhecimento e detectando possíveis problemas de saúde. A saúde inteligente usa uma nova geração de tecnologias da informação como a Internet das Coisas (IoT), *Big Data*, Computação em Nuvem e Inteligência Artificial, para monitorar e fornecer suporte e assistência em cuidados com a saúde, tornando a saúde mais eficiente, conveniente e personalizada (SUJITH *et al.*, 2022).

IoT surge como um paradigma onde a Internet é o meio que conecta pessoas e objetos a qualquer hora e em qualquer lugar. Através de dispositivos conectados, serviços e aplicações podem fornecer monitoramento e controle dos recursos de um ambiente, incluindo assim os Ambientes de Vida Assistida (AAL - *Ambient Assisted Living*, do inglês) (DUARTE *et al.*, 2018). Esses ambientes incorporam e integram objetos e pessoas de maneira não intrusiva e discreta, por meio de dispositivos inteligentes equipados com sensores, redes sem fio e aplicativos de software. O sistema monitora e captura informações do usuário e do ambiente fornecendo tecnologias assistivas para cuidados de saúde, suporte e assistência (AAL, 2021). Conforme ilustrado na Figura 1, o Ambiente de Vida Assistida possui artefatos inteligentes, serviços de comunicação, controle e monitoramento das ações e comunidade, ou participantes envolvidos.

Artefatos inteligentes incluem sensores que adquirem dados em fontes heterogêneas como, dispositivos incorporados aos objetos, ambiente e corporais, obtendo os dados que são

Figura 1 – Componentes de um Ambiente de Vida Assistida



Fonte: Adaptado de (PATEL; SHAH, 2021).

enviados para mecanismos de controle. O controle ou monitoramento incluem dentre outras abordagens, aprendizagem de máquina e ambientes inteligentes. Em *Ambient Assisted Living* (AAL) o processamento desses dados pelos mecanismos de controle pertence a um ciclo que define etapas de aquisição, processamento e análise de dados de sensores (PATEL; SHAH, 2021). Dados como localização do usuário, objetos utilizados (e.g., micro-ondas e cama), além da temperatura e postura corporal, podem ser extraídos, processados e analisados para fornecer informações úteis para tomada de decisão.

Na etapa de aquisição, os dados brutos de sensores adquiridos de fontes heterogêneas são avaliados sob as perspectivas de qualidade e incerteza dos dados. Problemas como falhas de *hardware*, falhas na rede de comunicação ou esgotamento de energia podem produzir resultados de baixa legibilidade. Na etapa de processamento de dados, técnicas e métodos de segmentação de dados são aplicados para preparar os dados para a etapa de análise de dados, que é responsável por interpretar os dados, fornecendo o conhecimento necessário para sistemas e aplicações

(PATEL; SHAH, 2021).

A segmentação de dados se encaixa nos desafios ligados à etapa de processamento de dados. Muitas aplicações dependem da interpretação de fluxos de dados gerados continuamente, exigindo métodos que identifiquem e dividam o fluxo em intervalos, segmentos ou janelas que podem ser analisados para extrair conhecimento. Conforme (SFAR; BOUZEGHOUB, 2019) a segmentação é um fator importante capaz de diminuir ou aumentar a precisão de um método de reconhecimento de atividade.

Na literatura existem dois principais métodos de segmentação de dados (FU, 2011): os métodos baseados em uma janela de tempo fixa e os métodos de janela de tempo dinâmica. A primeira abordagem usa um tamanho de janela de tempo fixo. A principal desvantagem deste método é a definição de uma janela de tempo potencialmente muito curta ou muito longa, favorecendo assim a ocorrência de resultados e interpretações errôneos. O segundo método para segmentação de dados usa um tamanho de janela de tempo dinâmica, i.e., adequando o tamanho da janela por meio de informações inicialmente capturadas. Estudos nesse tópico (OKEYO *et al.*, 2014; WAN *et al.*, 2015; SFAR; BOUZEGHOUB, 2019; TRIBOAN *et al.*, 2019), assumem que o comportamento do residente é variável, contudo, não combinam semanticamente os eventos gerados pelos sensores para reconhecer atividades do usuário ou Atividade da Vida Diária (AVD): esse é um processo conhecido como Reconhecimento de Atividade Humana (RAH).

O RAH é uma área de pesquisa emergente, especialmente em AAL para monitoramento de saúde dos idosos. A aquisição dos dados ocorre principalmente de forma *online*, ou seja, é necessário capturar, processar e fornecer respostas para detecção e reconhecimento contínuo de atividades assim que as primeiras ações ocorrem. Assim, as aplicações podem fornecer respostas adequadas através do ambiente, emitir alerta para cuidadores, informando uma situação de perigo, dentre outras aplicabilidades.

A difusão de tecnologias AAL corrobora para uma disponibilidade crescente de dados coletados de forma contínua. Portanto, há uma oportunidade e um desafio de detecção *online* a partir de fluxos de dados que forneçam conhecimentos úteis. Por exemplo:

"Considere um sistema para o monitoramento e RAH implantado na residência de uma idosa, chamada Joana, uma senhora que vive sozinha. Existem sensores de câmera que podem capturar os objetos que estão sendo utilizados (e.g., uma tigela) e a postura de Joana (e.g., sentada). Além disso, sensores podem ser implantados em objetos que Joana utiliza. Um sensor de presença pode ser usado para detectar

o ambiente em que Joana está (e.g., cozinha). Se Joana apresenta problemas de memória, é importante que os cuidadores sejam alertados na ocorrência de anormalidades. Contudo, analisando as ações capturadas pelo monitoramento é possível deduzir que Joana possui atividades com durações variáveis, portanto, reconhecer precisamente essas atividades pode ser importante. Além disso, pessoas com o perfil de Joana podem precisar de assistência durante a limpeza ou para preparar alimentos. Consequentemente, os fluxos de dados obtidos pelos sensores devem ser prontamente disponibilizados para os sistemas responsáveis por interpretar e fornecer respostas proativamente em vias de fornecer a melhor assistência possível para Joana nessas situações."

Sistemas de RAH que apoiam a detecção contínua da vida diária das pessoas, como é o caso da Joana, utilizam os segmentos gerados para interpretar as ações e inferir atividades. Portanto, os segmentos e todos os metadados oriundos de uma detecção, como, sensores, eventos, pessoas e técnicas envolvidas no processo de segmentação devem ser fornecidos para esses sistemas. Assim, ontologias podem ser úteis para representar essas informações, interpretando e disponibilizando metadados para anotação do segmento. Algumas ontologias existentes (COMPTON *et al.*, 2012; KOLOZALI *et al.*, 2014; BERMUDEZ-EDO *et al.*, 2016; ELSALEH *et al.*, 2020) definem metadados sobre os dispositivos ou fluxo de dados, mas não definem metadados resultantes do processo de segmentação de fluxo de dados de sensores.

## 1.2 Motivação

A segmentação de dados é uma tarefa de processamento responsável por definir as janelas de tempo adequadas para análise e processamento dos dados (PATEL; SHAH, 2021). O reconhecimento de AVD como preparar uma refeição pode ser definida por ações que envolvem o uso de objetos como, por exemplo, ao pegar uma tigela ou abrir o micro-ondas. Além disso, quando as ações não acontecem em um horário de referência ou em uma ordem, esse conhecimento pode ser útil para detecção de anormalidades. Portanto, essas aplicações são exemplos de consumo dos segmentos resultantes de uma tarefa de segmentação de dados.

Os problemas em RAH receberam grande atenção nos últimos anos através de diversos projetos de pesquisa. Esses projetos disponibilizam seus conjuntos de dados adquiridos em ambientes de controle e monitoramento, como, casas inteligentes, informando sobre seus experi-

mentos, comunidade envolvida e tipo de apoio prestado. Esses aspectos apoiam pesquisadores na validação de suas abordagens. Entre os projetos citados, temos:

- *Center for Advanced Studies in Adaptive Systems (CASAS)* (CASAS, 2021; COOK, 2010; COOK *et al.*, 2012) é um projeto desenvolvido pela *Washington State University*. O projeto utiliza sensores implantados em uma casa inteligente para monitorar atividades humanas. Através de agentes inteligentes e um conjunto de atuadores, o projeto dispõe de mecanismos de controle e prestação de assistência.
- Sistema Inteligente de Diagnóstico Antecipado e Acompanhamento Domiciliar (SECURE) (SECURE, 2021), é um projeto financiado pelo Ministério da Educação italiano, executado na região da Lombardia. Esse projeto propõe um sistema de RAH integrado com um novo método para detectar rotinas de atividades anormais em pessoas idosas. O conjunto de dados SmartFABER (RIBONI *et al.*, 2016) foi adquirido como parte do projeto interdisciplinar. Os dados do sensor foram adquiridos no apartamento de uma mulher idosa com diagnóstico de deficiência cognitiva leve.
- COCAPS (COCAPS, 2021) é um projeto financiado pelo Banco Público de Investimento Francês (BPI França) e coordenado pela Legrand. Um dos objetivos do projeto é dar autonomia aos idosos. Ao reconhecer uma atividade, o COCAPS pode recomendar ações para prevenir anomalias ou fornecer ajuda ao idoso na realização de suas atividades. Além disso, outro objetivo do COCAPS é projetar sensores de baixo custo para fornecer informações enriquecidas sobre comportamentos das pessoas no interior de um edifício, reconhecendo atividades diárias e fornecendo o suporte necessário para tomada de decisão em serviços de eficiência e autonomia energética (SFAR, 2019).

Dois aspectos norteiam e motivam essa tese. O primeiro aspecto diz respeito aos estudos recentes que apresentam abordagens cada vez mais robustas para RAH. No entanto, um problema crescente na segmentação de dados de sensores está relacionado aos eventos obtidos pelo fluxo de dados que podem conter ações dos residentes de AAL obtidas pelo mesmo sensor, mas que pertencem a atividades diferentes, gerando ambiguidade. Algumas atividades, tais como, preparar refeição, comer, ou limpar objetos, podem ser reconhecidas erroneamente quando as

abordagens propostas não combinam informações que apoiem a desambiguação das atividades. Um sensor implantando em um objeto que pode participar de diferentes atividades, inclusive, em uma mesma localização, pode não fornecer informações suficientes para desambiguação.

As abordagens que adotam algum recurso semântico, não correlacionam semanticamente conceitos sobre eventos obtidos através do comportamento previamente monitorado. Para interpretar ações, diferentes técnicas de segmentação podem ser adotadas, como baseadas em métricas, dados, conhecimento, ou híbridas. No contexto do problema de RAH, a segmentação de fluxos de dados de sensores pode adotar técnicas híbridas de processamento, obtendo as vantagens de técnicas baseadas em dados, onde esse comportamento pode ser adquirido e baseadas em conhecimento, onde a correlação pode ocorrer. Além disso, a combinação de eventos simples através do processamento de eventos complexos pode ser uma alternativa para essa problemática.

O segundo aspecto se baseia na problemática de anotação dos segmentos gerados pelos métodos de segmentação de fluxos de dados de sensores. As ontologias adotadas na literatura não dispõem de recursos para anotar os fluxos de dados segmentados com metadados que representem os segmentos e recursos envolvidos na representação do segmento (i.e, sensores, análise etc) (HALLER *et al.*, 2019; KOLOZALI *et al.*, 2014; BERMUDEZ-EDO *et al.*, 2016; ELSALEH *et al.*, 2020). Além disso, não permitem o rastreamento dos segmentos gerados (i.e., a possibilidade de identificar a proveniência do segmento atual).

As ontologias para anotação de fluxos são escassas e não são projetadas para reconhecer e interpretar segmentos que variam de acordo com o padrão de comportamento das pessoas nas suas AVD, muitas vezes, adequando os segmentos a períodos fixos (ELSALEH *et al.*, 2020).

A segmentação é uma tarefa de processamento importante para as aplicações, pois, uma escolha inadequada de janela pode causar impactos negativos na acurácia e precisão, dificultando a tomada de decisão por parte dos serviços e aplicações. Essa problemática motiva esta tese. Portanto, é necessário investigar e discutir melhorias nos resultados de acurácia e precisão das aplicações e serviços. Particularmente, fatores como adoção de técnicas híbridas, processamento de eventos complexos e representação do conhecimento, com foco na desambiguação de atividades, são desafios potenciais em aplicações de RAH.

Outro aspecto que motiva e reforça a necessidade de melhoria são as aplicações de RAH. Essas aplicações possuem ampla investigação na literatura, apresentando estudos relevantes que disponibilizam conjuntos de dados e resultados promissores.

### 1.3 Hipótese, Objetivo e Questões de pesquisa

Para os problemas levantados, essa tese apresenta duas hipóteses:

- **H1:** Em aplicações de reconhecimento de atividades, um método de segmentação de dados de sensores que utiliza eventos complexos como solução para desambiguação de atividades, garante melhoria na precisão e acurácia dessas aplicações.
- **H2:** A adoção de uma ontologia para anotação dos metadados de segmento permite consulta e rastreamento dos segmentos oriundos de recursos heterogêneos, sejam sensores ou técnicas aplicadas na segmentação.

Foram definidos experimentos ou validações (Seção 6) para confirmar essas hipóteses sobre o método híbrido de segmentação semântica proposto e o uso da ontologia proposta para anotação.

Diante dessa hipótese, o objetivo dessa tese é propor um método híbrido de segmentação de fluxos de dados de sensores e uma ontologia de anotação de segmentos, fornecendo suporte a sistemas e aplicações de RAH no contexto de AAL.

Este cenário descreve os problemas que devem ser enfrentados e elenca as seguintes questões de pesquisa:

- **QP1.** Quais técnicas de segmentação de dados podem ser adequadas para reconhecer e interpretar fluxos de dados de sensores?

Eventos gerados pelo mesmo sensor, podem pertencer a atividades diferentes, gerando ambiguidade. Este critério deve ser considerado para o reconhecimento de AVD. Reconhecer atividades é imprescindível para determinar sua duração habitual e útil para segmentação. Experimentos envolvendo o monitoramento de seres humanos geralmente possuem poucos dados e sensores, devido à privacidade, evitando o monitoramento do residente AAL por um longo período. Adotar conjuntos de dados conhecidos na segmentação de fluxos de dados de sensores é fundamental para uma comparação honesta entre os trabalhos. No entanto, o número de conjuntos de dados públicos no RAH é escasso (Costa Junior. *et al.*, 2022). Este é um problema limitante para algoritmos de aprendizagem máquina, que

são adotados para aprender o comportamento dos residentes. Por outro lado, técnicas baseadas em conhecimento exigem esforço e tempo dos especialistas para definir e manter um modelo atualizado.

- **QP2.** Quais abordagens podem ser adotadas para segmentar fluxos de dados de sensores garantindo desambiguação?

Para uma maior precisão, o tamanho da janela deve ser ajustado, considerando que diferentes atividades necessitam de tamanhos de janela diferentes. É desafiador definir eventos relevantes para um segmento em uma estratégia de processamento que garante melhoria no RAH, inferindo sua atividade correspondente, i.e., um único evento pode inferir diferentes atividades.

- **QP3.** Quais ontologias podem ser adotadas para representar metadados relacionados a segmentação dinâmica de fluxos de dados?

Os AAL fornecem sensores de fontes heterogêneas e processam o fluxos de dados para fornecer conhecimento em um ciclo de aquisição, processamento e análise de dados de sensores. Informações entre as etapas desse ciclo, particularmente, entre o processamento e análise, necessitam de representação. Tecnologias semânticas podem ser empregadas para fins de expressividade, consulta e rastreamento. Assim, resultados da segmentação dos dados devem ser representados, como os eventos, sensores, usuários, tempo de ocorrência e o segmento. Informações úteis para o rastreamento de diferentes resultados, métodos de análise, e conhecimento útil para diversas aplicações que necessitam, por exemplo, de dados sobre usuários e sensores utilizados em uma estratégia de reconhecimento multiusuário. Além disso, a segmentação dinâmica requer anotação de metadados sobre os segmentos, criando uma referência para as janelas geradas.

#### 1.4 Metodologia e Resultados Esperados

A metodologia usada nesta tese combina técnicas e conceitos de segmentação de fluxos de dados de sensores, conforme detalhados a seguir.

Para responder as **Questões de Pesquisa 1 e 2**, foi realizada uma revisão dos esforços

de pesquisa existentes em técnicas de segmentação de fluxos de dados de sensores e ontologias para anotação de segmentos, no que diz respeito ao RAH. Esta revisão também considerou técnicas baseadas em dados, conhecimento e híbridas para segmentação de dados, destacando limitações, desvantagens e desafios em aberto. Os detalhes podem ser encontrados no Capítulo 2.

Um método híbrido de segmentação de fluxos de dados de sensores é desenvolvido neste trabalho, combinando técnica baseada em dados, utilizando aprendizagem supervisionada, e técnica baseada em conhecimento, adotando ontologia e regras de inferência, para segmentação dinâmica de fluxos de dados de sensores. Para isso, é necessário como entrada, um conjunto de dados sobre o monitoramento de um residente, contendo eventos, atividades e intervalos de duração. Essas informações são adotadas para inferência *online* de atividades que foram aprendidas pelo comportamento do usuário. Para tanto, a adaptação semântica recorre a ontologia e regras de inferências para raciocinar e definir o melhor tamanho de janela ou segmento.

Para responder a **Questão de Pesquisa 3**, após revisão da literatura sobre anotação de segmentos, em particular, utilizando ontologias, foi observada uma lacuna nesse tópico de pesquisa que motivou o desenvolvimento de uma ontologia para anotar segmentos oriundos da segmentação dinâmica de fluxos de dados de sensores, utilizando ontologias conhecidas e novos conceitos. A ontologia é concebida para representar diferentes domínios de aplicação e seu vocabulário, relações e exemplos de instanciação encontram-se disponíveis no Capítulo 4 desta tese.

Como resultado esperado é apresentado um novo método híbrido para segmentação de fluxos de dados de sensores aplicado a Ambientes Vida Assistida, particularmente, ao RAH. Este método apoia a segmentação dinâmica de fluxos de dados de sensores que combina eventos simples em um enfoque voltado a desambiguação de atividades. Ainda como resultado esperado dessa tese, é desenvolvida uma ontologia para anotar os segmentos resultantes da segmentação dinâmica de fluxos de dados de sensores.

## 1.5 Organização da tese

O restante desta tese está organizada da seguinte forma. No Capítulo 2, a fundamentação teórica é apresentada, em particular, são trabalhos relacionados a AAL, com ênfase no RAH. São apresentados ainda trabalhos que propuseram técnicas de segmentação de fluxos de dados baseados em métricas, dados, conhecimento e híbridas. O Capítulo 3 aborda os trabalhos

relacionados e o Capítulo 4 descreve a ontologia para anotação de segmentos e exemplos de instanciação. O Capítulo 5 discute o método híbrido proposto, sua arquitetura e etapas de implementação. No Capítulo 6, define-se a avaliação sobre a ontologia para anotação e o método, discutindo os experimentos em conjuntos de dados conhecidos. Finalmente, o Capítulo 7 é dedicado ao desenvolvimento das considerações finais acerca desta tese, incluindo conclusões e indicações de trabalhos futuros.

## 2 FUNDAMENTAÇÃO TEÓRICA

Esse capítulo aborda a fundamentação teórica em Ambientes de Vida Assistida incluindo seu ciclo de aquisição, processamento e análise dos dados de sensores. Considerando as questões de pesquisa dessa tese, um mapeamento sistemático foi realizado em técnicas de segmentação de fluxos de dados de sensores. Além disso, uma investigação sobre Processamento de Eventos Complexos encontra-se nesse capítulo, pois, definições sobre eventos e seu processamento são necessárias para segmentação de fluxos de dados de sensores. Ainda nesse capítulo, conceitos sobre Ontologia são apresentadas para apoiar o entendimento sobre os recursos semânticos adotados nos Capítulos 4 e 5 dessa tese.

A seguinte estrutura é utilizada nesse capítulo. Na Seção 2.1, os trabalhos sobre AAL, aquisição, processamento, análise e aplicação em RAH. Em seguida, na Seção 2.2, técnicas de segmentação de fluxos de dados de sensores são apresentadas e discutidas. Na Seção 2.3, são discutidas definições sobre eventos, eventos simples e processamento de eventos complexos. Por fim, na Seção 2.4, definições sobre Ontologia. Este capítulo termina com as considerações finais sobre o que foi discutido nesse capítulo.

### 2.1 Ambientes de Vida Assistida

Ambientes Vida Assistida são ambientes equipados com sensores e dispositivos de computação embutidos que atendem os usuários e controlam o ambiente por decisões cientes do contexto (DUARTE *et al.*, 2018). O objetivo desses ambientes é fornecer dispositivos inteligentes que coletam e processam dados continuamente para fornecer conhecimento aos usuários e tornar a vida diária confortável, agradável e personalizada.

O Ambiente Vida Assistida é um campo multidisciplinar emergente que visa explorar tecnologias de informação e comunicação que atua em sistemas de saúde pessoal e telessaúde da população idosa. Os sistemas AAL são desenvolvidos para atender a requisitos personalizados, adaptativos e antecipatórios, exigindo alta qualidade de serviço para alcançar interoperabilidade, usabilidade, segurança e precisão (MEMON *et al.*, 2014).

Sensores implantados em AAL detectam estados ou ações físicas. A Tabela 1 mostra uma lista dos tipos comuns de sensores usados em casas inteligentes. Cada sensor é usado para medir uma das propriedades físicas como temperatura, luminosidade, movimento, uso de objetos, etc.

Tabela 1 – Lista dos tipos de sensores mais comuns em casas inteligentes

Sensor	Objetivo
Temperatura	Termostatos inteligentes ajustam as temperaturas individuais, possibilitando economia de energia e conforto
Luminosidade	Detecção de luz, ajuste de brilho e definição de horários de iluminação.
Movimento	Detecta movimento, podendo auxiliar no reconhecimento de atividades, monitoramento de saúde e suporte a segurança.
Porta e janela	Economia de dinheiro e segurança.
Vibração	Envolve a detecção de batidas em uma porta, janela ou abrir a porta do guarda roupa.
Pressão	Mede a pressão e gera um sinal relacionado à pressão imposta. Comumente utilizado em camas, poltronas e demais assentos.
Acelerômetro	Mede a aceleração, que é a taxa de variação da velocidade de um objeto. Em dispositivos vestíveis, pode detectar uma queda de um ocupante.
Ultrassônico	Mede a distância. Quando implantados em cômodos ou objetos, possibilita sua detecção e monitoramento do (s) ocupante (s).

Fonte: Elaborado pela autora (2023).

Em AAL, existe uma variedade de sensores e cada tipo de sensor fornece dados conforme as especificações dos fabricantes em formatos próprios. Consequentemente, adquirir e processar esses dados de fontes heterogêneas torna-se um desafio. Além disso, muitas aplicações, como as aplicações de RAH, demandam aquisição e interpretação *online* dos fluxos de dados de sensores, possibilitando uma resposta proativa ao usuário. Essa condição, exige soluções que promovam eficácia e eficiência nas etapas de tratamento e interpretação dos dados.

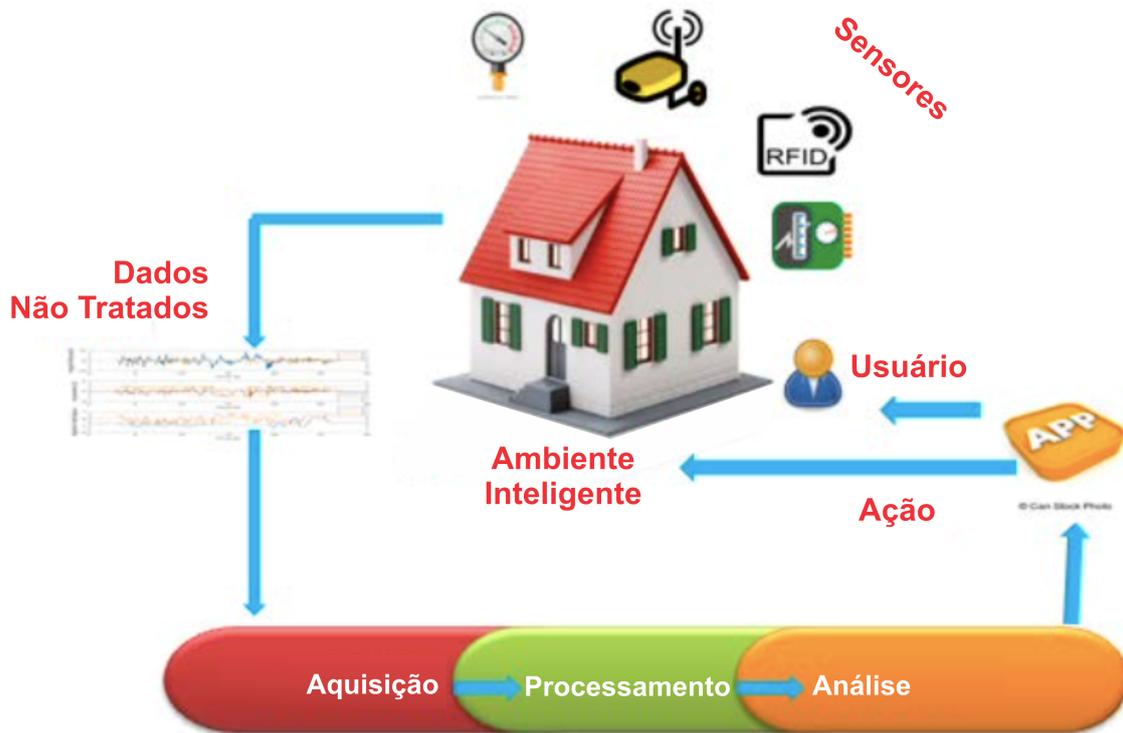
A Figura 2 apresenta uma arquitetura de AAL para aplicações de tomada de decisão, detalhando o ciclo desde a coleta dos fluxos de dados até a análise realizada por aplicações e serviços.

Os dados brutos fornecidos pelos sensores têm um ciclo, conforme apresentado na Figura 2, começando na aquisição que posteriormente fornece uma nova versão dos dados para o processamento até uma etapa de análise. Esse ciclo compreende as abordagens necessárias para auxiliar a aquisição do fluxo de dados até que o resultado seja útil para tomada de decisão pelas aplicações. Nas próximas subseções, uma visão geral de cada etapa desse ciclo de vida é discutida.

### 2.1.1 Aquisição de Dados e Processamento

Na etapa de aquisição de dados, os fluxos de dados brutos coletados por sensores implantados em AAL são adquiridos e transformados. Dentre as tarefas possíveis nessa etapa destaca-se a limpeza de dados ruidosos e tratamento de incerteza (CUGOLA *et al.*, 2015; JARRAYA *et al.*, 2016; BONTE *et al.*, 2018).

Figura 2 – Arquitetura de AAL para aplicações de tomada de decisão



Fonte: Adaptado de (SFAR, 2019).

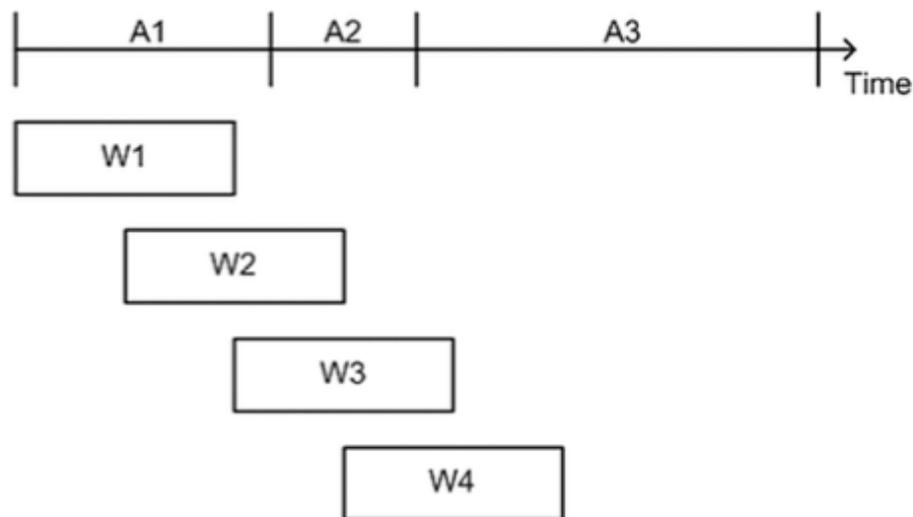
A etapa de aquisição de dados possui literatura bastante explorado, apresentando métodos conhecidos para tratamento de incertezas. Assim, como exemplo de abordagem conhecida, é possível destacar o sistema *Fuzzy Semantic Complex Event Processing* (FSCEP) (JARRAYA *et al.*, 2016) para aquisição de dados. O sistema calcula os valores de incerteza através de uma abordagem difusa, que oferece vantagens quando comparadas aos outros sistemas. Após a coleta e tratamento dos dados brutos obtidos pelos sensores, as abordagens disponibilizam dados passíveis de processamento.

Na etapa de processamento os dados são preparados para análise e interpretação. Uma tarefa importante dessa etapa é a segmentação de dados. O processo de segmentação divide os dados em um conjunto de segmentos, também chamados de janelas, ou intervalos de tempo. Posteriormente, cada segmento pode ser analisado separadamente por abordagens encontradas na etapa de análise. O resultado dessa tarefa pode impactar diretamente nos resultados de análise, pois, o resultado do processamento envolve além do próprio segmento, os eventos, ou, dados brutos obtidos. Portanto, definir o tamanho do segmento implica em uma resposta com eventos ou dados relevantes para aplicação ou insuficientes, impactando assim na precisão ou acurácia das aplicações.

Na literatura, existem duas estratégias de segmentação: (1) Estática (FU, 2011;

KASTEREN *et al.*, 2008) e (2) Dinâmica (LAGUNA *et al.*, 2011; OKEYO *et al.*, 2014; WAN *et al.*, 2015). Quando a segmentação é estática significa que o tamanho do segmento é fixo, onde geralmente são encontradas janelas de 60 segundos. Após algumas tentativas, a aplicação escolhe o tamanho de segmento que fornece melhores resultados. Na Figura 3, a janela deslizante estática com sobreposição é utilizada para classificar atividades.

Figura 3 – Classificação de atividades com janela deslizante estática



Fonte: Adaptado de (NOOR *et al.*, 2017)

Seja,  $A_1$ ,  $A_2$  e  $A_3$  durações das atividades e  $J_1$ ,  $J_2$ ,  $J_3$  e  $J_4$ , janelas, ou segmentos. Apenas a duração da atividade  $A_2$  é mais curta do que o tamanho de janela definido, enquanto as durações das atividades  $A_1$  e  $A_3$  são mais longas, o que sugere que os eventos que envolvem essas atividades não são totalmente segmentados pelas janelas  $J_1$ ,  $J_2$  e  $J_4$ . Em ambos os casos, o reconhecimento incorreto de atividade pode ocorrer porque as janelas não têm informações ideais sobre as atividades para definir janelas adequadas (NOOR *et al.*, 2017).

Por outro lado, na segmentação dinâmica o tamanho do segmento é escolhido dinamicamente por métodos que interpretam informações sobre as atividades para definir um tamanho de janela adequado. A maioria dos trabalhos estabelece eventos correspondentes para reconhecer com maior assertividade uma atividade em curso.

### 2.1.2 Análise de Dados

Após o processamento dos fluxos de dados de sensores o segmento de dados precisa ser analisado para tomada de decisão. O conhecimento obtido nessa etapa pode ser aplicado no

RAH, detecção de anomalias ou na previsão de atividades futuras (YIN *et al.*, 2008; HUSSAIN *et al.*, 2019). Esse conhecimento provê suporte amplo para aplicações em diferentes domínios, como saúde, segurança e transporte.

As anomalias são consideradas desvios do comportamento normal. Assim, o efeito de um processamento e análise inadequados pode gerar alerta ou avaliações errôneas do estado atual de um residente AAL. Detectar atividades ou possíveis anomalias é um tópico essencial, especialmente para aplicações de saúde. Assim, são necessários recursos e abordagens que forneçam precisão no reconhecimento para que as necessidades potenciais de assistência sejam atendidas. Nesse contexto, essa tese possui enfoque no RAH, com objetivo de provê suporte para etapa de análise nesse domínio.

Na próxima seção foram definidos o que são sistemas de RAH elencando trabalhos da literatura.

### **2.1.3 Reconhecimento de Atividade Humana**

Existem diferentes aplicações propostas na literatura para tomada de decisão em AAL. As técnicas, algoritmos ou ferramentas aplicadas na etapa de análise dependem do propósito da aplicação. Como exemplo de aplicação útil é possível citar o gerenciamento de energia baseado na atividade do usuário (NGUYEN; AIELLO, 2013; ALGHAMDI *et al.*, ). Em particular, essa tese discute o processamento e análise dos fluxos de dados de sensores no escopo de aplicações de RAH.

Os usuários costumam realizar ações como, gestos, movimentos e usar objetos em sua rotina diária. Os sistemas de RAH interpretam os dados para reconhecer ações que dentro da rotina habitual do residente denotam suas atividades. Na literatura foram encontradas três categorias principais com base nas técnicas aplicadas para o RAH: métodos baseados nos dados, baseados em conhecimento e híbridos.

O RAH baseado em dados usa aprendizado de máquina supervisionado e não supervisionado, além de métodos estatísticos em dados de sensores. Abordagens que implementam essa técnica necessitam de um conjunto de dados inicial para aprender sobre o comportamento do residente. Por exemplo:

Para conseguir inferir que atividade Joana poderia estar executando, previamente, é necessário monitorar Joana por algum tempo para obter um conjunto de dados com sua rotina. Esse conjunto de dados são os eventos, objetos e posições que ocorreram

e que foram anotadas manualmente para atividades, por especialistas no domínio. Os algoritmos de aprendizagem utilizam esse conjunto de dados para definir um modelo de predição, que posteriormente poderá classificar atividades com certo nível de precisão. Para citar alguns esforços de pesquisa: Rede Lógica de Markov, ou *Markov Logic Network* (MLN) (GAYATHRI *et al.*, 2017), Rede Bayesiana (LIU *et al.*, 2017) e Árvores de decisão (BAO; INTILLE, 2004). Esses trabalhos apresentam os pontos fortes destas abordagens no processo de aprendizagem.

Embora os métodos orientados a dados consigam lidar com incertezas, essas abordagens requerem muitas instâncias de dados de sensores para treinamento e não permitem a reutilização do modelo, impossibilitando a adaptação em ambientes diferentes. Além disso, se a sequência em que os eventos são obtidos e os metadados referentes a essa sequência são necessários para definir atividades em curso, esse tipo de abordagem não consegue definir essa semântica.

Por outro lado, as abordagens orientadas ao conhecimento (OKEYO *et al.*, 2014; CHEN *et al.*, 2013) modelam atividades dependentes do conhecimento prévio dos recursos no ambiente, sejam objetos, sensores ou pessoas. Entre as abordagens, é possível citar o uso de ontologias e Lógica de Descrição (LD). O processo de modelagem envolve a associação de dados de sensores de baixo nível às atividades consideradas de alto nível, como, por exemplo, quando o usuário entra no banheiro e liga o chuveiro. Essas são consideradas sub atividades que podem ser representadas pela atividade, tomar banho. O RAH segue então uma inferência lógica ou raciocínio de subsunção, conforme o caso.

Essa modelagem de representação do conhecimento alimenta uma base de conhecimento que pode ser genérica, ou não se adapta ao padrão de comportamento de diferentes residentes, ocasionando uma falha no reconhecimento da atividade. Esse fator pode afetar a qualidade de monitoramento e assistência. Por exemplo:

"Para definir atividades de Joana utiliza-se uma base de conhecimento comum. Objetos de uso, posições humanas durante o uso desses objetos podem fazer parte, ou não, de uma atividade de Joana. Se, para tomar uma medicação Joana utiliza uma tigela pois seu medicamento deve ser consumido com algum alimento, essa atividade deve provavelmente ir diferir da modelagem de conhecimento de senso comum em que o copo é o objeto de uso, utilizado nesses contexto, e, bebendo, a posição para uma atividade de tomar medicação."

Em comparação com a técnica baseada em dados, as técnicas baseadas em conhecimento são mais expressivas, semanticamente ricas e as inferências geralmente estão em um formato que é facilmente entendido, ou seja, legível para máquinas e seres humanos. Contudo, essas técnicas são ineficientes quando se refere ao tratamento de incertezas.

Por fim, as técnicas híbridas (CHEN *et al.*, 2013; RIBONI; BETTINI, 2011; CIVITARESE *et al.*, 2019a) enfrentam um interesse crescente para o RAH devido à sua capacidade de superar problemas tanto em técnicas baseadas em conhecimento quanto em técnicas orientadas por dados (HELAOUI *et al.*, 2013). Os métodos que implementam essa técnica definem etapas que devem utilizar algoritmos de aprendizagem e conhecimento. Assim, implementando essa técnica para monitorar Joana, um passo seria necessário para aprender com a rotina de Joana e posteriormente definir semanticamente a sequência em que os eventos ocorrem para inferir atividades.

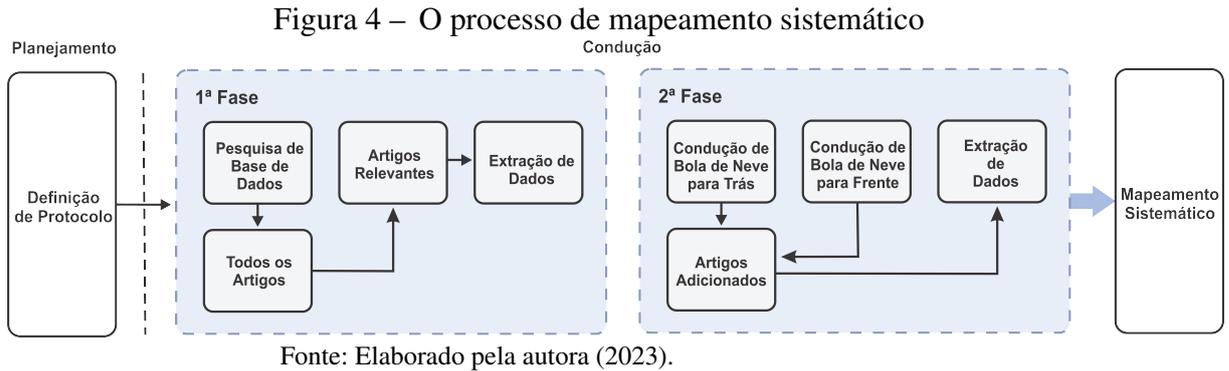
## 2.2 Técnicas de Segmentação de Fluxos de Dados

Esta seção apresenta técnicas de segmentação de fluxos de dados de sensores aplicadas aos sistemas de RAH. Para tanto, um estudo de mapeamento sistemático (KITCHENHAM *et al.*, 2010) foi adotado para identificar, avaliar e interpretar trabalhos relevantes. Na literatura, a adoção desse formato de pesquisa define que os resultados do uso de um processo controlado e de uma pesquisa bibliográfica formal, beneficiam a comunidade de pesquisa ao listar tópicos de interesse, lacunas e desafios.

Associado ao estudo de mapeamento sistemático, foi realizado o procedimento de bola de neve (WOHLIN, 2014), uma abordagem de pesquisa sistemática que usa *backward* (ou seja, verificar as referências dos estudos) e *forward* (ou seja, verificar artigos que citaram os estudos) para identificar artigos adicionais, a fim de ampliar o conjunto de trabalhos considerados nessa tese.

Um processo baseado em diretrizes para a realização de mapeamentos sistemáticos da literatura proposto por Kitchenham e Charters (KITCHENHAM; CHARTERS, 2007) foi seguido, conforme apresentado na Figura 4. O processo consiste em três atividades principais: planejamento, condução e relatório.

A atividade de planejamento visa definir o protocolo, organizando as etapas da pesquisa. E a atividade de condução foi executada em duas fases distintas. Primeiro, foram selecionados estudos primários usando bibliotecas digitais. Em seguida, o procedimento bola de



neve obteve um conjunto de artigos que foi somado aos demais.

O objetivo da fase de planejamento é a definição de um protocolo de mapeamento. O protocolo de mapeamento sistemático (KITCHENHAM; CHARTERS, 2007) define as questões de pesquisa a serem respondidas, *string* de busca, fontes de pesquisa e como os artigos são selecionados. O objetivo desse estudo identificou técnicas de segmentação de fluxos de dados de sensores aplicada aos sistemas de RAH. Em particular, foram definidas as seguintes questões de pesquisa:

**QP1** Que técnicas de segmentação de fluxos de dados de sensores foram aplicadas ao Reconhecimento de Atividade Humana?

**QP2** Que métodos de segmentação podem ser encontrados na literatura?

**QP3** Quais são as principais metodologias adotadas para avaliar cada trabalho?

A *string* de pesquisa é baseada na abordagem PICO (P — paciente, problema ou população; I — intervenção; C — comparação, controle ou comparador; O - resultado) (PAI *et al.*, 2004) e nos termos-chave da pesquisa, a seguinte *string* foi elaborada: (“internet of things” OR “iot” OR “human activity recognition”) AND (“hybrid” OR “data oriented” OU “knowledge oriented”) AND (“state of the art” OR “survey” OR “approach” OR “techniques” OR “system”).

Para obter os estudos primários, dois métodos foram adotados: pesquisa nas bases de dados e bola de neve. Para a busca nas bases de dados, as bibliotecas digitais mais relevantes em Ciência da Computação e Engenharia (CHEN *et al.*, 2010) foram selecionadas: (a) ACM Digital Library (ACM, 2021); (b) Biblioteca Digital IEEE Xplore (XPLORE, 2021); e (c) Science Direct (SCIENCEDIRECT, 2021). Em relação à abordagem de bola de neve, foram adotados os procedimentos *backward* e *forward* (WOHLIN, 2014).

Critérios de seleção foram definidos para selecionar os estudos mais adequados,

onde: os estudos devem ser escrito em inglês; estudos com publicação até o mês de Maio de 2023; os estudos selecionados devem estar disponíveis na Web e o estudo deve apresentar iniciativas relacionadas as questões de pesquisa. Nenhuma restrição foi definida com base no tipo de trabalho, o que significa que foram escolhidos todos os tipos de estudos, como artigos de conferências e revistas, artigos curtos, devido o número reduzido de trabalhos encontrados, e completos. Eles foram processados da mesma forma considerando os critérios de seleção citados.

A etapa de condução foi realizada em duas fases. A primeira fase está relacionada à realização de pesquisas em base de dados, que visa encontrar artigos relevantes em bibliotecas digitais usando strings de pesquisa bem definida. A segunda fase está relacionada à condução do *backward snowballing*, ou seja, busca de artigos nas listas de referências dos artigos identificados durante a primeira fase, e à realização do *forward snowballing*, ou seja, busca de artigos que citaram os artigos encontrados na primeira fase.

Na primeira fase, são selecionados artigos com base no protocolo definido. O conjunto de strings de busca foi aplicado aos motores de busca: ACM, IEEE Xplore e Science Direct. Esta etapa recuperou 37 artigos, 19 do ACM, 13 do IEEE Xplore e 5 do Science Direct. Após a aplicação dos critérios de seleção, foram rejeitados 31 artigos e 6 artigos permaneceram.

Na segunda fase, o procedimento de bola de neve é geralmente executado com um conjunto inicial de estudos. Nessa pesquisa, o conjunto inicial correspondeu aos 6 artigos selecionados na primeira fase da atividade de condução. Além disso, foi executado um procedimento *snowballing* para encontrar estudos adicionais. Ao final, foram obtidos mais 12 artigos, totalizando 18 artigos para extração de dados.

Na Tabela 2, é possível observar os trabalhos encontrados na literatura e as técnicas aplicadas, sejam elas, baseada em dados, baseada em conhecimento ou uma técnica híbrida e um resumo de lacunas e desafios encontrados na segmentação de fluxos de dados de sensores aplicadas ao RAH.

Na Tabela 3, encontram-se os estudos e métodos encontrados nas técnicas de segmentação, apresentadas na Tabela 2. Além disso, esses estudos são separados por ano de publicação.

Nessa seção, trabalhos em segmentação de fluxos de dados de sensores aplicadas ao RAH foram apresentados considerando técnicas: (1) baseadas em métricas, (2) baseadas em dados, (3) baseadas em conhecimento e (4) híbridas. Nas próximas seções, essas técnicas são

Tabela 2 – Técnicas de segmentação de fluxos de dados de sensores aplicadas ao Reconhecimento de Atividade Humana

Técnicas	Artigo	Lacunas e Desafios
Baseada em Métricas	(WAN <i>et al.</i> , 2015)	O cálculo de correlação não faz uso de características sobre eventos.
Baseada em Dados	(MALLICK <i>et al.</i> , 2018), (DONG <i>et al.</i> , 2020), (PAN <i>et al.</i> , 2019), (RAWASHDEH <i>et al.</i> , 2020), (KRISHNAN; COOK, 2014), (ASGHARI <i>et al.</i> , 2020)	Permitem a classificação das amostras observadas. Contudo, esses modelos não correlacionam semanticamente eventos.
Baseada em Conhecimento	(CIVITARESE <i>et al.</i> , 2018), (TRIBOAN <i>et al.</i> , 2017), (TRIBOAN <i>et al.</i> , 2019), (YE <i>et al.</i> , 2015), (YE <i>et al.</i> , 2014), (OKEYO <i>et al.</i> , 2014)	Garantem interpretação e expressividade para fornecer o enriquecimento das informações. Muitos adotam um modelo genérico, de senso comum e assumem que o comportamento do residente não muda
Híbridas	(SFAR; BOUZEGHOUB, 2019), (SFAR, 2019), (SALGUERO <i>et al.</i> , 2018), (CIVITARESE <i>et al.</i> , 2019b) (DÍAZ-RODRÍGUEZ <i>et al.</i> , 2014)	Semanticamente expressivo e considera o padrão de comportamento do residente. A combinação de modelos aumenta a complexidade devido à heterogeneidade de fontes e técnicas de análise e processamento.

Fonte: Elaborado pela autora (2023).

Tabela 3 – Métodos de segmentação de fluxos de dados de sensores aplicados ao Reconhecimento de Atividade Humana

Artigo	Ano	Métodos adotados
(DÍAZ-RODRÍGUEZ <i>et al.</i> , 2014) (KRISHNAN; COOK, 2014) (OKEYO <i>et al.</i> , 2014) (YE <i>et al.</i> , 2014)	2014	Aprendizagem de Máquina e Ontologia difusa Aprendizagem Probabilística Ontologia Ontologia
(WAN <i>et al.</i> , 2015) (YE <i>et al.</i> , 2015)	2015	Correlação de Pearson Ontologia
(TRIBOAN <i>et al.</i> , 2017)	2017	Ontologia
(MALLICK <i>et al.</i> , 2018) (CIVITARESE <i>et al.</i> , 2018) (SALGUERO <i>et al.</i> , 2018)	2018	Clusterização Hierárquica Lógica e Consulta semântica Ontologia e Aprendizagem Probabilística
(PAN <i>et al.</i> , 2019) (TRIBOAN <i>et al.</i> , 2019) (SFAR; BOUZEGHOUB, 2019; SFAR, 2019) (CIVITARESE <i>et al.</i> , 2019b)	2019	<i>Ensemble Learning</i> <sup>2</sup> Ontologia Clusterização e Ontologia Inferência Semântica e MLN
(DONG <i>et al.</i> , 2020) (RAWASHDEH <i>et al.</i> , 2020) (ASGHARI <i>et al.</i> , 2020)	2020	Distribuição Gaussiana Aprendizagem Probabilística Modelo oculto de Markov

Fonte: Elaborado pela autora (2023).

apresentadas e discutidas.

### 2.2.1 Baseadas em Métricas

As técnicas baseadas em métricas estabelecem o tamanho do segmento conforme o resultado de métricas calculadas (WAN *et al.*, 2015). Em (WAN *et al.*, 2015), os autores propõem um método de segmentação dinâmica que consiste em adotar a métrica de correlação *Pearson Product Moment Correlation* (PMC), uma medida da correlação linear (dependência) entre duas variáveis para calcular a correlação entre qualquer par de eventos de sensores para definir o segmento. Para calcular a correlação entre sensores, o estudo utiliza a localização do sensor como característica que define a proximidade dos sensores, assim, sensores nas mesmas áreas de funcionamento, ou próximas, são prováveis de serem acionados juntos, ou sequencialmente. Para calcular a correlação de tempo, calcula-se o *timestamp* inicial e o último de evento de sensores. O tamanho limite do segmento é definido pela duração máxima das atividades.

O tratamento de eventos de entrada de acordo com sua correlação com a localização do sensor pode adicionar eventos irrelevantes ao segmento. Além disso, existe a dificuldade em desambiguar as atividades, uma vez que utiliza a localização do sensor como evento para definir uma atividade. Por exemplo:

"Utilizando somente a localização, como a cozinha, e o uso de um copo por Joana, pode-se denotar uma atividade de preparar refeição, comer ou de limpeza. Alternativamente, a abordagem poderia usar outros eventos, inerentes ao comportamento do usuário, modelando uma ontologia que considera os relacionamentos entre os eventos e as AVD."

### 2.2.2 Baseadas em Dados

Em geral, essas técnicas adotam métodos de aprendizado de máquina para descobrir o melhor tamanho de segmento em relação aos eventos de sensores. Normalmente, são dados pré-segmentados, ou seja, dados com tamanhos de janelas fixos. O aprendizado ocorre tanto em uma abordagem *offline* onde um conjunto de dados é obtido e armazenado baseado em um tempo limite, por exemplo, atividades capturadas por 35 dias, ou, podem ocorrer através de uma abordagem *online*, aprendendo a medida que novos segmentos são definidos.

Os autores em (KRISHNAN; COOK, 2014) propõem o uso de uma abordagem de aprendizagem probabilística para identificar inicialmente o tamanho da janela, usando um conjunto de dados pré-segmentados. Como segunda etapa, eles propõem aprender o tamanho

de janela provável para uma atividade com base nas probabilidades calculadas dos tamanhos de janela possíveis. Para o cálculo baseado em ponderação, os autores adotam duas métricas, a deterioração do tempo e informação mútua. A fim de decidir o resultado do último evento do sensor, os autores adotam um fator de ponderação baseado no tempo para cada evento do sensor em relação ao tempo do último evento do sensor. A informação mútua ou dependência entre dois sensores é então definida como a chance de esses dois sensores ocorrerem consecutivamente em todo o fluxo do sensor. Os autores avaliam às duas métricas separadamente e em conjunto, utilizando a acurácia como métrica de avaliação para o RAH. Os autores concluem que os resultados obtidos com base no esquema de ponderação de tempo não é uniformemente eficaz, pois, o desempenho se deteriora em alguns conjuntos de dados testados, além disso, a avaliação de informação mútua impulsionou o desempenho geral em uma média de 7% em relação a *baseline*. A combinação das métricas resultou em um desempenho que está próximo do resultado obtido com o esquema de ponderação baseado no tempo.

Em (MALLICK *et al.*, 2018), os autores propõem uma técnica de segmentação em três etapas TSF, temporal, sensor e frequência. Na etapa temporal (T), o intervalo entre atividades é aprendido em uma fase de treinamento. Caso essa etapa adicione erroneamente eventos relacionados a outras atividades no segmento atual, as etapas de sensor (S) e frequência (F) são requeridas para reduzir ou minimizar esse problema. Na etapa de sensor, os autores adotam agrupamento hierárquico, considerando que os sensores fazem parte da mesma atividade se a distância do sensor for baixa. A etapa de sensor não pode separar atividades sobrepostas que usam um conjunto semelhante de sensores para expressá-las, assim a frequência também pode ser usada para segmentar. Os autores avaliam as etapas de segmentação através de estratégias temporais como, por exemplo, a segmentação diurna. Avaliando diferentes conjuntos de dados, constataram que existe diurnidade nas atividades humanas, ou seja, atividades em frequências diferentes em vários momentos do dia. O algoritmo adotado para aprender a diurnidade não obteve resultados significantes, adicionando eventos irrelevantes aos segmentos, esse fator pode estar relacionado ao aprendizado que não adotou diferentes informações contextuais sobre as atividades, facilitando a desambiguação.

Os trabalhos (PAN *et al.*, 2019) e (DONG *et al.*, 2020) utilizam os sinais de vibração, detecção elétrica e acelerômetro emitidos pelos sensores para segmentar eventos, sendo potencialmente compostos de várias janelas de sinal. Os autores em (PAN *et al.*, 2019) propõem um mecanismo de votação por maioria ponderada se houver mais de dois sensores que detectam

a janela deslizante como parte de um evento. Os autores avaliaram a precisão do reconhecimento de atividades. Em (DONG *et al.*, 2020), um algoritmo de janela adaptativa é proposto para estimar a razão de sobreposição para cada evento. Contudo, para selecionar o melhor comprimento para a janela deslizante, os autores analisaram várias durações de janela e selecionaram o valor que maximizou a acurácia do reconhecimento de atividade. Os autores avaliam a segmentação que usa janelas adaptativas e a abordagem sem janelas adaptativas.

Os autores (RAWASHDEH *et al.*, 2020) apresentam métodos para resolver a ambiguidade resultante de atividades concorrentes e intercaladas. Além disso, o tempo dos eventos é abstraído em categorias significativas para capturar as relações contextuais entre os eventos temporais. Como exemplo, os autores citam a abstração de *timestamps* dos sensores em categorias significativas (Manhã, Tarde e Noite), permitindo que os classificadores correlacionem semanticamente os resultados nos segmentos de dados. Os autores também propõem uma técnica de janela deslizante dinâmica que calcula o tamanho da janela para cada evento do sensor com base em uma abordagem probabilística. Um conjunto de tamanhos de janela fixos é definido para cada atividade, e o tamanho da janela para um determinado sensor é escolhido baseado no tamanho que maximiza a probabilidade condicional de uma atividade associada ao sensor. Os autores avaliam a acurácia do reconhecimento de atividade.

Por fim, no trabalho (ASGHARI *et al.*, 2020), os autores adotam Modelos Ocultos de Markov (EDDY, 1996), implementados de forma hierárquica a fim de reconhecer o início, estimar a atividade em andamento, detectar o fim e a classe das atividades. O método aprende através do padrão sequencial dos dados dos sensores no início e no término de cada atividade. O método também conta com uma fase de correção onde o turno e a duração das atividades são utilizadas para desambiguação. Os autores avaliam a acurácia do reconhecimento de atividade.

### **2.2.3 Baseadas em Conhecimento**

Esta técnica aplica principalmente representação semântica, utilizando ontologia e raciocínio semântico através de inferência lógica, para definir dinamicamente o tamanho da janela. A segmentação consiste em expandir ou reduzir a janela de tempo através do resultado de consulta a uma ontologia.

O trabalho (OKEYO *et al.*, 2014) apresenta uma nova abordagem de segmentação que usa a informação temporal das observações do sensor para segmentação dinâmica e modelos de atividade descritos usando ontologia. As heurísticas propostas consideram a duração da

atividade e os recursos semânticos para reduzir e expandir uma janela de tempo dinâmica de atividades. A ontologia AVD adotada determina se ativações adicionais do sensor devem ser antecipadas ou não. Se não houver mais ativações de sensor esperadas ou se a duração tiver se esgotado, a janela de tempo atual é fechada e uma nova janela de tempo é ativada. O método é avaliado através dos resultados de acurácia do reconhecimento de atividade.

No trabalho (YE *et al.*, 2014) os autores apresentam uma abordagem de segmentação semântica de dados de sensor online baseado na semântica temporal, espacial e de objeto de eventos de sensor. Na proposta de segmentação os autores adotam a similaridade semântica usando medida de distância *Least Common Subsumer* (LCS), entre dois eventos de sensor adjacentes para segmentar dinamicamente os fluxos de sensores em tempo real.

Os autores em (YE *et al.*, 2015) adotam uma abordagem baseada no conhecimento para reconhecimento de atividade concorrente (KCAR). KCAR explora a semântica dos eventos do sensor no modelo ontológico. A abordagem usa descrições conceituais das entidades cotidianas dentro do Ambiente de Vida Assistida usando uma ontologia de domínio para realizar comparação de similaridade usando medida de distância *Least Common Subsumer* (LCS) entre dois nós. Por exemplo, a similaridade de distância seria mais próxima entre as classes Geladeira e Fogão na hierarquia do que Geladeira e Computador. O método usa a similaridade de tempo que compara a similaridade temporal entre os eventos do sensor e a similaridade do sensor nos conceitos de localização e objeto utilizado, que estão associados aos sensores. Além disso, o estudo afirma reconhecer atividades multiusuário. Comparado a duas abordagens clássicas de janela deslizante estática, o KCAR pode detectar o limite de atividades simultâneas com mais precisão e produzir um número menor de partições que se assemelham melhor às atividades reais.

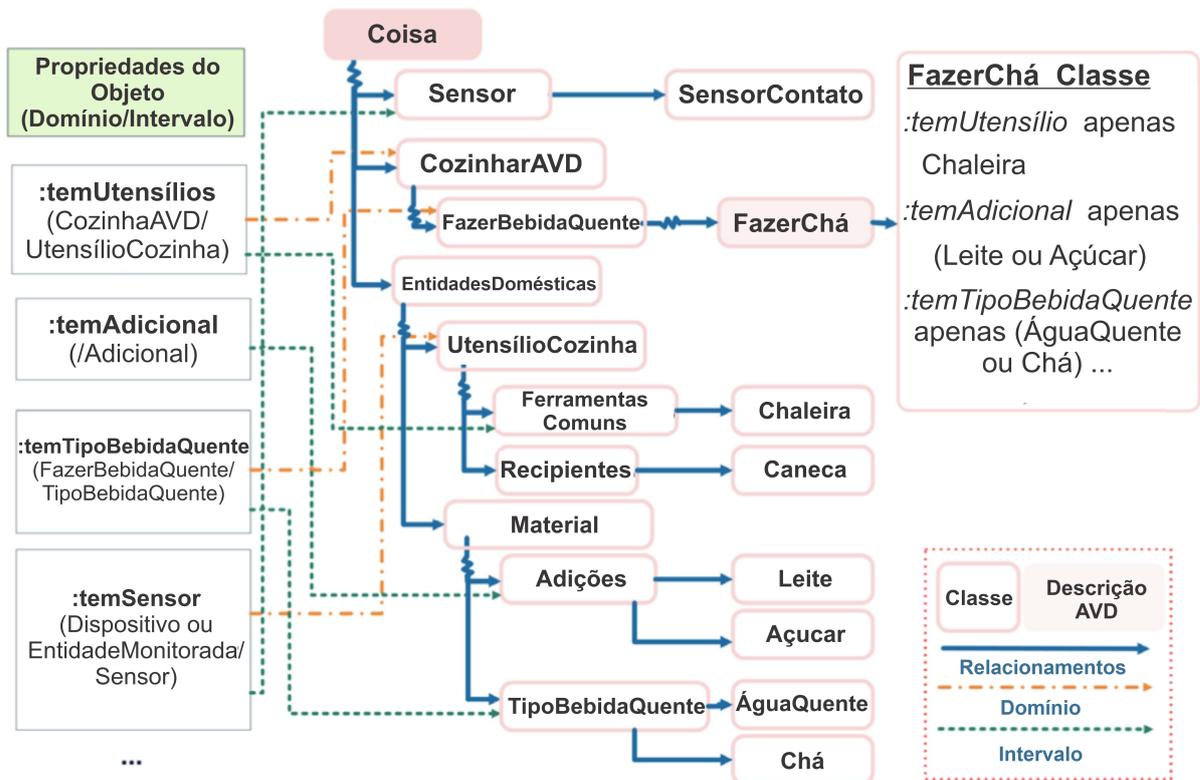
No trabalho (TRIBOAN *et al.*, 2017) os autores codificam o conhecimento de domínio em um modelo de ontologia AVD que permite ao usuário definir preferências e regras. No método proposto, o raciocinador tem acesso à ontologia de domínio através de linguagens de consulta baseadas em SPARQL (SIRIN; PARSIA, 2007), extraindo os recursos como tipo de atividade, contexto e duração total. O estudo de caso aborda segmentação semântica para um residente idoso que apresenta um grau leve de demência, mas não apresenta uma avaliação comparativa dos resultados.

Os autores (CIVITARESE *et al.*, 2018) apresentam uma camada de segmentação baseada em regras online. O método de segmentação é baseado em regras semânticas que

consideram diferentes aspectos como restrições de tempo, interação de objetos e mudança de localização. Se pelo menos uma das condições for atendida, o segmento atual é finalizado. A função dessas regras é agrupar os eventos consecutivos que mais provavelmente se originam da mesma instância de atividade. Assim que um segmento é finalizado, ele é processado pela camada de decisão de consulta para decidir se dispara ou não uma consulta de *feedback*. O residente é consultado de modo a fornecer uma classe de atividade para o segmento. Isso limita o número de consultas feitas ao residente. Um dos aspectos que os autores não abordam são as correlações entre atividades e padrões temporais de eventos, descrevendo esse aspecto como trabalhos futuros.

A segunda fase da abordagem proposta por (TRIBOAN *et al.*, 2019) é de segmentação semântica, onde é possível organizar os eventos de sensor observados com base nas atividades em andamento ou detectar novas atividades realizadas por um único habitante. Para tomar decisões de segmentação, uma ontologia é adotada para verificar os links de associação entre os objetos e os sensores, informações contextuais, objetos utilizados, preferências genéricas e específicas dos habitantes para realizar AVDs e suas relações semânticas (Figura 5).

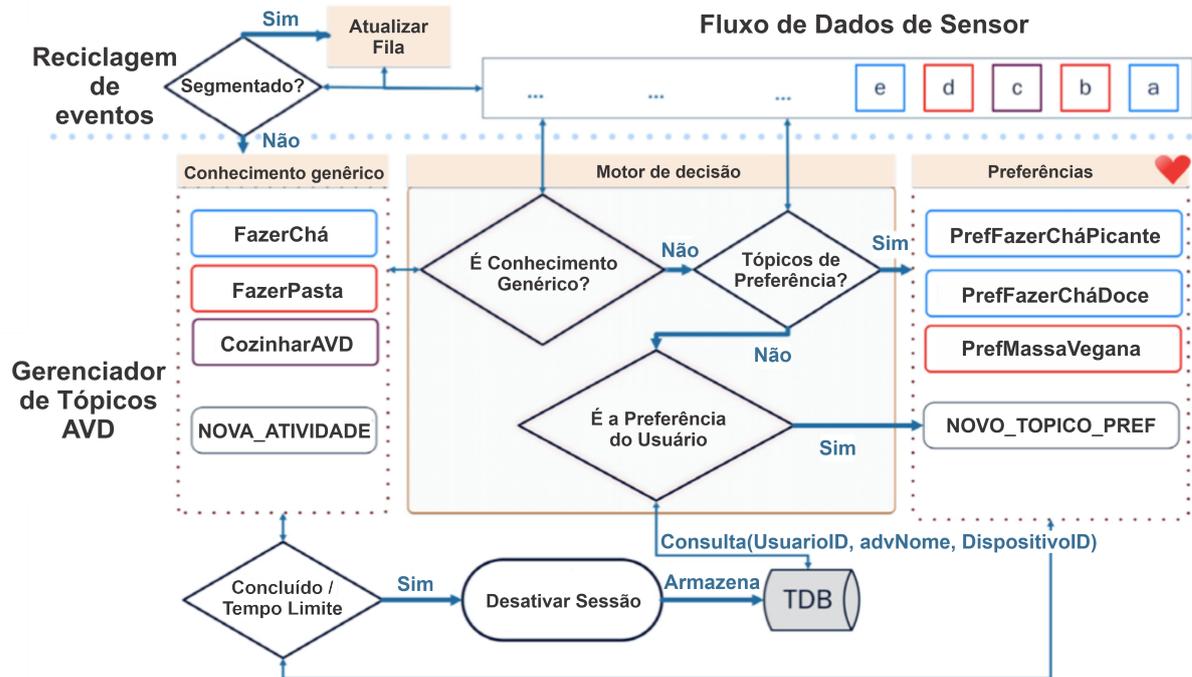
Figura 5 – Propriedades de relacionamento semântico entre objetos do cotidiano, conjunto de ações para AVD FazerChá e características do sensor.



Fonte: Adaptado de (TRIBOAN *et al.*, 2019)

Uma abordagem semântica é desenvolvida para tomar decisões de segmentação com base em três entradas: o novo evento de sensor observado, o modelo ontológico e um conjunto de sensores previamente segmentados para uma dada atividade.

Figura 6 – Visão geral da abordagem de segmentação habilitada semanticamente para raciocínio com Base de Conhecimento genérica (T-box) e de preferências (A-box).



Fonte: Adaptado de (TRIBOAN *et al.*, 2019)

Conforme Figura 6, após a ativação do sensor, o evento é inspecionado por um ou mais *threads* executadas em paralelo. Cada *thread* AVD depende de um mecanismo de decisão de dois estágios para encontrar qualquer associação com o evento do sensor observado. O mecanismo de decisão conduz o raciocínio *T-box* com a base de conhecimento genérica no primeiro estágio e o raciocínio *A-box* com evento de sensor observado e preferências específicas do habitante ao consultar o *triplestore* no segundo estágio. O segundo estágio do mecanismo de decisão só é invocado quando o uso da entidade em que o sensor observado está anexado tem uma contradição ou não foi explicitamente especificado na descrição genérica da AVD. Os autores avaliam acurácia e o tempo médio de segmentação.

#### 2.2.4 Híbridas

Abordagens baseadas em métricas pressupõe que vários eventos e atividades de sensor devem ser correlacionados. Em relação às abordagens baseadas em dados, um conjunto

de dados de treinamento de dados de sensores pré-segmentados é essencial para o processo, contudo, as características que as abordagens utilizam não possuem relações entre eventos e o contexto em que elas acontecem. Os métodos anteriores baseados em conhecimento geralmente supõem que o comportamento não muda entre residentes. No entanto, esta suposição não é realista.

Assim, para superar essas dificuldades, algumas abordagens híbridas foram desenvolvidas, incluindo os principais benefícios proporcionados pelas técnicas baseadas em dados e o uso de ontologia, ou seja, de recursos encontrados nas técnicas baseadas em conhecimento. Desse modo, os modelos ontológicos AVD capturam e codificam um rico conhecimento de domínio e heurísticas de uma forma compreensível por máquina.

Como exemplo de estudos que adotam técnicas híbridas temos (SALGUERO *et al.*, 2018; SFAR; BOUZEGHOUB, 2019; SFAR, 2019; CIVITARESE *et al.*, 2019b; DÍAZ-RODRÍGUEZ *et al.*, 2014). Após o estudo aprofundado sobre as diferentes técnicas de segmentação, as técnicas híbridas são adotadas nessa tese. Portanto, esses estudos são discutidos em trabalhos relacionados (Capítulo 3, Seção 3.1).

### 2.3 Processamento de Eventos Complexos

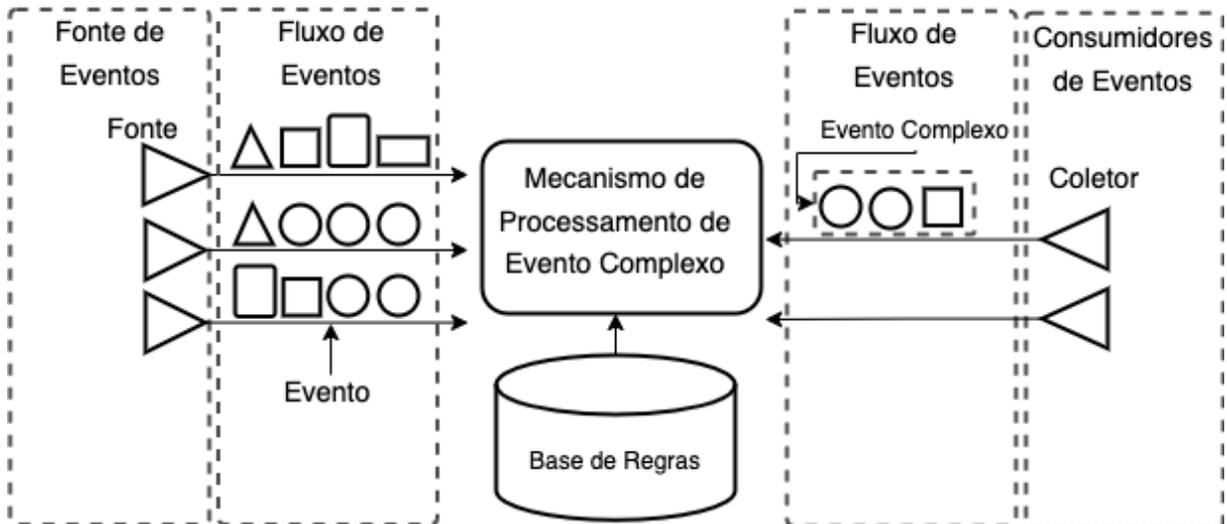
Um evento pode ser definido como uma ocorrência, ou observação de interesse no tempo (PETERSEN *et al.*, 2016). A frequência cardíaca de uma pessoa, a velocidade onde a pessoa corre, o uso de um copo, o movimento de beber água utilizando esse objeto, são exemplos de eventos. Os eventos podem ser categorizados como simples ou complexos, por exemplo, a frequência cardíaca, o uso de um sensor implantado em um objeto, pode ser considerada um evento simples, enquanto as correlações sobre muitos eventos simples, como o uso de um objeto e a postura humana, podem ser considerados eventos complexos. O tempo de ocorrência é um atributo comum a todos os eventos (PETERSEN *et al.*, 2016).

Se um evento não pode ser dividido em eventos menores, ele é chamado de evento simples. Um evento complexo é um evento derivado de uma consulta de evento expressa por meio de regras definidas. Um fluxo de eventos  $S = \{E_1, \dots, E_n\}$  contém  $n$  eventos de interesse sendo considerado heterogêneo (incluindo eventos simples e complexos).

O processamento de eventos complexos, do inglês *Complex Event Processing* (CEP), é a tarefa de associar ou combinar eventos simples para identificar situações de alto nível, baseando-se em regras definidas (CHEN *et al.*, 2014). Esse conceito é bastante difundido na

literatura para processamento de dados. Uma visão geral de processamento de eventos complexos é ilustrada na Figura 7.

Figura 7 – Visão de alto nível de CEP.



Fonte: Adaptado de (PETERSEN *et al.*, 2016)

As fontes de eventos são sensores que detectam mudanças em seu ambiente. O módulo de mecanismo de processamento de evento complexo processa esses eventos que estão disponíveis de acordo com um conjunto de regras. Essas regras especificam como combinar ou associar eventos simples para gerar novos Eventos Complexos (EC) que representam a saída do mecanismo (PETERSEN *et al.*, 2016). Os consumidores de eventos, também chamados de coletores, são os destinatários de tal saída.

Em sistemas de processamento de eventos complexos, eventos são escolhidos como entradas para derivação de regras, que conseqüentemente definem seu relacionamento para finalmente fornecer o conjunto de padrões de regras que derivam eventos mais complexos. No entanto, existe uma complexidade em derivar tais regras e sua implantação pode ser manual ou automática. Em (MEHDIYEV *et al.*, 2016), os autores propõem o uso de aprendizagem de máquina, adotando classificadores baseados em regras para substituir a identificação manual de regras. A principal ideia é a detecção de padrões de regras em um processo *offline*, fornecendo as regras obtidas que podem identificar eventos complexos em fluxos de dados. Por fim, o processamento de eventos utilizando CEP, verifica se os eventos capturados atendem as condições específicas dos padrões de regras definidos. Derivando eventos mais complexos que podem, por exemplo, em uma aplicação de RAH, devem ser as atividades.

Um objetivo comum para as aplicações e serviços que adotam CEP é monitorar

e correlacionar dados provenientes de diferentes sensores em tempo real e tomar as medidas necessárias. O monitoramento remoto da saúde é uma aplicação potencial do CEP que ganhou importância significativa com o advento da IoT (AKBAR *et al.*, 2019). As principais abordagens envolvem a implantação de diferentes sensores, dispositivos vestíveis, que coletam informações dos pacientes para obter informações sobre o comportamento dos pacientes. Tratando-se de dados que podem afetar a segurança ou conforto dos pacientes, esses dados necessitam de análise em tempo quase real. Eventos como, pressão arterial ou nível atual de açúcar no sangue representa associado com outros eventos, como atividades físicas do paciente, informações alimentares podem resultar em conhecimento de alto nível importante para tomada de decisão.

Aplicações CEP encontradas na literatura fornecem soluções reativas à medida que os eventos acontecem. Em uma associação de fluxos de dados quase em tempo real para detectar eventos complexos (AKBAR *et al.*, 2019). Contudo, algumas abordagens associam CEP e aprendizado de máquina (FÜLÖP *et al.*, 2012; WANG; CAO, 2014; AKBAR *et al.*, 2017), assumindo a disponibilidade de dados estatísticos, para efeito de construção do modelo de aprendizagem de máquina e previsão de eventos complexos.

Uma tarefa desafiadora na implantação de CEP em IoT, ou em AAL, são os requisitos de processamento de dados que podem ser definidos em segundos ou até milissegundos. Portanto, ainda é um desafio mensurar a melhoria de desempenho associada a adoção de CEP e aprendizado de máquina.

## 2.4 Ontologia

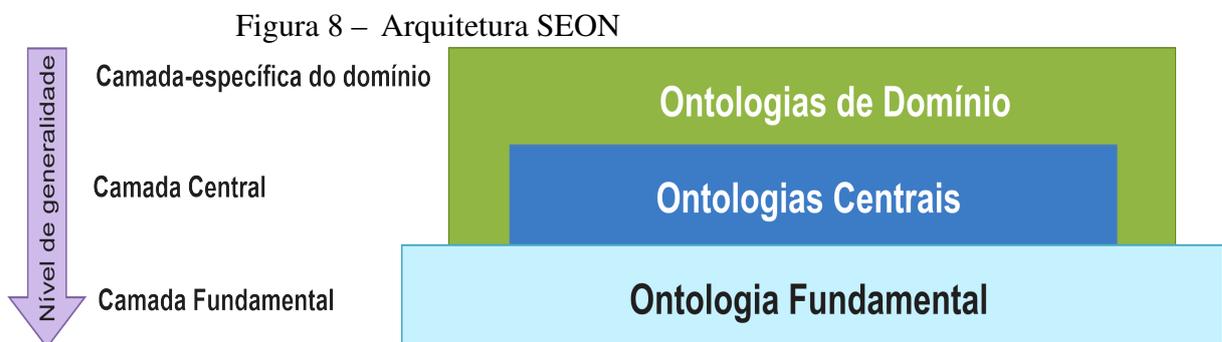
A ontologia é uma especificação formal explícita de como representar entidades que existem em um determinado domínio de interesse e os relacionamentos que existem entre elas (GUBER, 1993). Uma ontologia permite a representação de conhecimento através de uma estrutura comum e flexível que facilita o compartilhamento das bases de conhecimento entre sistemas heterogêneos.

As ontologias possuem conceitos (ou classes), que são, geralmente, organizados em hierarquias e são mais complexas que as taxonomias porque não consideram apenas relações de tipo, mas também consideram outras relações específicas de domínio (KNIJFF *et al.*, 2013). As ontologias fornecem vocabulários estruturados que explicam e representam as relações entre os termos. Em uma ontologia, o símbolo  $\top$  representa o conceito superior da hierarquia, todos os outros conceitos sendo subconjuntos de  $\top$ . A relação de subsunção é geralmente expressa

usando o símbolo  $A \sqsubseteq B$ , o que significa que o conceito A é um subconjunto do conceito B. Os conceitos também podem ser especificados como combinações lógicas de outros conceitos.

Ontologias descritas em linguagens formais podem ser utilizadas por diferentes aplicações para compartilhar e armazenar conhecimento (KEPLER *et al.*, 2006). O OWL é uma linguagem padrão para representação de ontologias desenvolvida pela *World Wide Web Consortium* (W3C) (HEFLIN *et al.*, 2007), projetado para suportar a *Web Semântica*. OWL herda características de várias famílias de linguagens de representação, incluindo lógica de descrição. *Semantic Web Rule Language* (SWRL) é uma linguagem de regras baseada em OWL (HORROCKS *et al.*, 2004). Ele permite que os usuários escrevam regras que podem ser expressas como conceitos OWL para fornecer recursos de raciocínio dedutivo. O uso de um raciocinador permite a verificação formal da ontologia.

A literatura oferece diferentes classificações de tipos de ontologias. Uma que é bem aceita é a classificação segundo o nível de generalidade da ontologia proposta em (PRESTES *et al.*, 2013). Nessa classificação, existem ontologias de nível superior, ontologias núcleo, ontologias de domínio e ontologias de aplicação (Figura 8).



Fonte: Adaptado de (RUY *et al.*, 2016)

Ontologias de nível superior ou fundamentais, definem conceitos gerais e independentes de domínio, como, espaço, tempo, objeto, processo e relacionamentos dessas entidades, como parte e subsunção. As ontologias de nível superior mais conhecida na literatura são DOLCE (GANGEMI *et al.*, 2002), SUMO (NILES; PEASE, 2001), GFO (HERRE, 2010), UFO (GUIZZARDI, 2005) e BFO (ARP *et al.*, 2015). Uma ontologia núcleo define os termos centrais de um campo específico, geralmente vinculando os termos gerais de uma ontologia de nível superior aos conceitos mais específicos de domínio (OBERLE, 2006). O número de classes que uma ontologia central contém não é necessariamente alto. As ontologias de nível superior servem como base para o desenvolvimento de ontologias de núcleo, e as ontologias de núcleo servem

como base para o desenvolvimento de ontologias de domínio (SCHERP *et al.*, 2011). Ontologias de domínio e aplicação representam o vocabulário relacionado a um domínio específico.

Para desenvolver ontologias, boas práticas foram definidas pela comunidade de *Web Semântica* (NOY *et al.*, 2001). Na perspectiva dessa tese, o processo de segmentação possui recursos que devem ser compartilhados com os consumidores, ou seja, os sistemas de RAH. O interesse principal é responder como a publicação do processo de segmentação funcionará, i.e., o volume de dados produzido é considerável. Para tanto, uma ontologia para anotação de metadados de segmentos deve adotar conceitos existentes de outras ontologias ou vocabulários que podem enriquecer o modelo com metadados úteis para descrever o conceito principal, permitindo o rastreamento. Assim, é necessário representar os conceitos relacionados ao segmento e os recursos utilizados, fornecendo suporte para publicação e posterior consumo. É importante notar que esses conceitos precisam ser flexíveis, pois, os formatos de observação podem variar entre os sistemas.

## 2.5 Considerações Finais

Ao longo deste capítulo, a fundamentação teórica em AAL e o ciclo de aquisição, processamento e análise de dados sensorizados foi apresentada. O enfoque do capítulo foi o processamento de fluxos de dados de sensores. Assim, foi necessário investigar as diferentes técnicas de segmentação de dados de sensores. Particularmente, o processamento de dados e técnicas híbridas, associando essas técnicas a problemas de reconhecimento de atividades para processar os dados e fornecer segmentação dinâmica de fluxos de dados de sensores. Por isso, foram investigados trabalhos que discutem esses três tópicos.

Também foram definidos aspectos sobre o processamento de eventos complexos. Esse tópico está relacionado ao tipo de evento que é processado para obtenção da janela dinâmica. Trabalhos da literatura utilizam diferentes sensores, processando individualmente os eventos coletados. No entanto, é possível processar eventos simples, combinando esses eventos, com objetivo de obter inferências mais precisas sobre as ações e atividades que estão ocorrendo. Por fim, conceitos sobre ontologia núcleo e ontologia de anotação são definidos para o entendimento das propostas encontradas nos Capítulos 4 e 5.

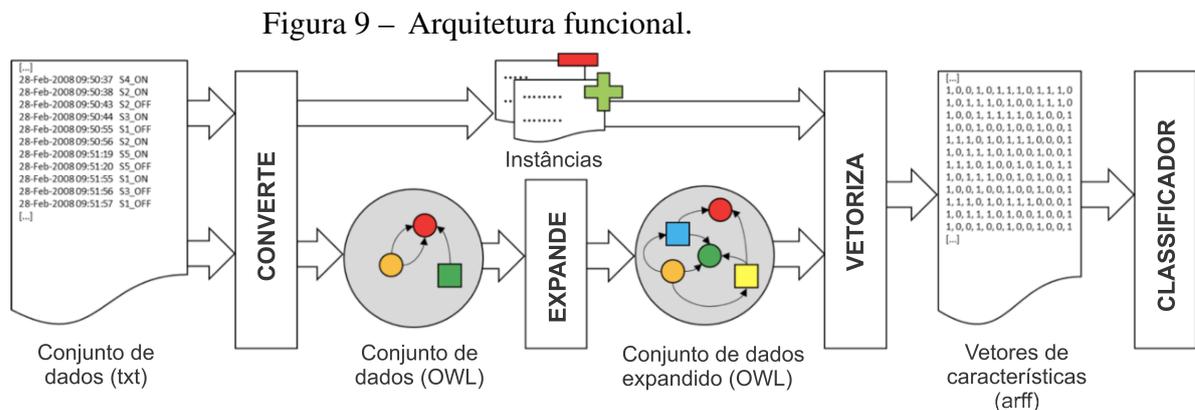
### 3 TRABALHOS RELACIONADOS

Esse capítulo aborda os trabalhos relacionados em técnicas híbridas de segmentação (veja Seção 2.2.4) de fluxos de dados de sensores na Seção 3.1. Além disso, ele trata de ontologias para anotação semântica de fluxos de dados na Seção 3.2, ressaltando as principais vantagens e desvantagens de cada abordagem e realizando uma comparação entre as abordagens.

#### 3.1 Técnicas Híbridas de Segmentação de Fluxos de Dados

Algumas abordagens híbridas foram desenvolvidas para incluir vantagens encontradas pelo uso de técnicas baseadas em dados e de técnicas baseadas em conhecimento.

Na abordagem (SALGUERO *et al.*, 2018) os autores adotam uma abordagem híbrida que classificam como segmentação baseada no tempo e baseada em eventos. Inicialmente, uma segmentação baseada no tempo é adotada para definir os eventos relevantes em uma janela temporal deslizante para cada atividade. O tamanho ideal da janela temporal deslizante é adaptado por uma análise estatística. Assim é possível definir as atividades e sua duração. Utilizando o resultado dessa análise, a proposta coleta os eventos em circunstâncias reais, segmentando os eventos e adicionando em ontologias.



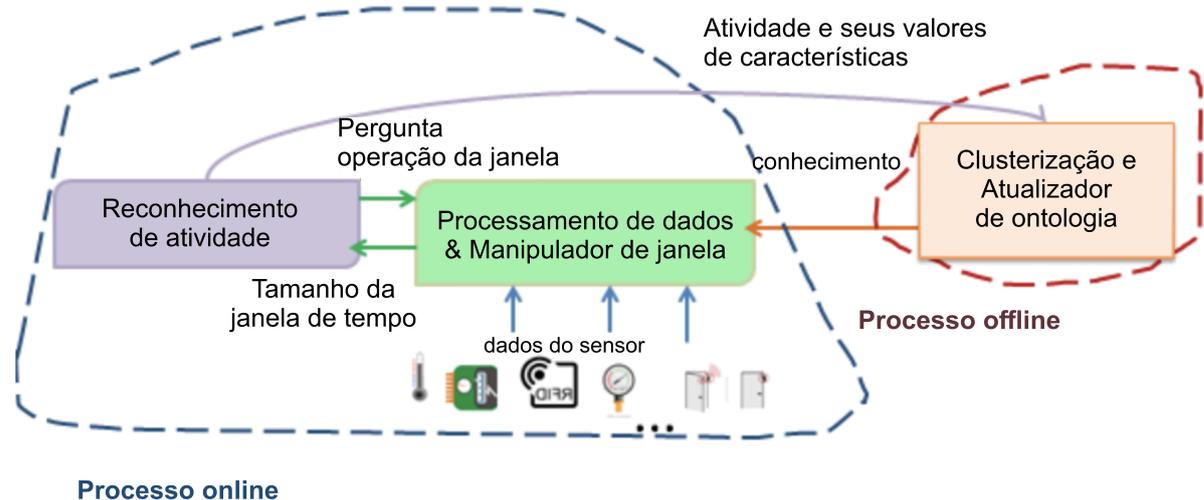
Fonte: Adaptado de (SALGUERO *et al.*, 2018)

Na Figura 9, a abordagem proposta (SALGUERO *et al.*, 2018) instancia uma ontologia durante o processo de segmentação, combinando conceitos e propriedades para gerar novos conceitos. Esses conceitos também fornecem conhecimento para descrever as atividades sob uma representação mais rica e interpretável. Adotando LD, novos eventos podem ser inferidos e são úteis para os algoritmos de aprendizagem supervisionada que produzem o modelo de classificador. Os classificadores utilizados no experimento são C4.5, Otimização Sequencial

Mínima, Perceptron Votado, Florestas Aleatórias e Tabela de Decisão. Para avaliar os resultados, os autores utilizaram medida F para o conjunto de dados Singla e Ordonez, obtendo resultado de 0,86. Além disso, o estudo classificou corretamente 85,25 das instâncias para o conjunto de dados Kasteren (KASTEREN *et al.*, 2008). Os autores não utilizam aprendizagem de máquina para aprender sobre o comportamento individual de um usuário.

No trabalho (SFAR; BOUZEGHOUB, 2019; SFAR, 2019) os autores apresentam um método híbrido denominado DataSeg. DataSeg combina um algoritmo de Clusterização com um método baseado em ontologia. Esta hibridização permite escolher dinamicamente o melhor tamanho da janela de tempo.

Figura 10 – Visão geral da abordagem de segmentação habilitada semanticamente para raciocínio com Base de Conhecimento genérica (T-box) e de preferências (A-box).



Fonte: Adaptado de (SFAR; BOUZEGHOUB, 2019)

Conforme Figura 10, DataSeg não requer dados pré-segmentados, ou seja, o método aprende o comportamento de um residente com um conjunto de dados inicial. Posteriormente, o conjunto de dados de treinamento é adquirido e o agrupamento é realizado *offline*, o resultado do agrupamento atualiza uma ontologia que é criada para obter as instâncias com o comportamento do usuário para consulta posterior. Para um reconhecimento *online*, a ontologia se comunica com o módulo de reconhecimento de atividades para decidir qual o melhor tamanho para a janela de tempo atual. O resultado de uma consulta a ontologia será uma atividade e sua duração é utilizada para definir a janela de tempo. DataSeg aguarda a saída da aplicação responsável pelo reconhecimento da atividade e verifica sua exatidão com base na consulta realizada nas instâncias da ontologia. Quando a saída da aplicação não é satisfeita, o DataSeg estende o tamanho do segmento. Os autores avaliam o método usando o resultado de acurácia e medida F, comparando

com abordagens que usam janela estática e um método baseado em métrica que usa a medida de informação mútua para calcular a correlação do sensor. A adaptação do tamanho da janela depende de uma resposta da aplicação, exigindo uma maior troca de informações e pode afetar o desempenho da tarefa de segmentação dinâmica.

O método de segmentação proposto em (CIVITARESE *et al.*, 2019b), denominado POLARIS, considera dependências de tempo e localização, além das correlações de atividade e objeto de uso do fluxo de dados de eventos. Os autores adotam o raciocínio ontológico para inferir essas dependências probabilísticas entre tipos de eventos de sensor e classes de atividades executadas, denotando essas operações como correlações semânticas. Primeiro, o fluxo de eventos do sensor é continuamente segmentado considerando várias condições probabilísticas e semânticas. Finalmente, o algoritmo de análise estatística de segmentos analisa os últimos  $k$  segmentos gerados de modo a derivar candidatos a instâncias de atividade considerando as correlações semânticas obtidas da ontologia. O algoritmo de segmentação online considera cinco aspectos: interação do objeto, mudança de contexto, probabilidade de consistência, salto de tempo e mudança de localização. O aspecto de interação do objeto finaliza um segmento assim que o POLARIS detecta que o usuário parou de interagir com todos os objetos na casa. O aspecto mudança de contexto considera o modelo ontológico para verificar se o novo evento no fluxo está correlacionado com o último evento do segmento atual. O aspecto de probabilidade de consistência verifica se o segmento atual inclui eventos rotulados principalmente com a mesma classe de atividade. Aqui os autores consideram todo o conjunto de eventos do segmento. O aspecto salto no tempo considera a distância no tempo entre eventos consecutivos. Portanto, o aspecto salto no tempo não é considerado para o primeiro segmento. O aspecto mudança de local depende do fato de que a maioria das AVDs são realizadas em um local específico.

A combinação desses aspectos visa agrupar eventos de sensor que provavelmente pertencem à mesma instância de atividade. No entanto, quando a duração de uma instância de atividade é particularmente longa, adotar apenas esses aspectos, pode gerar segmentos que se estendem por um longo período. A saída da camada de raciocínio de correlação semântica é considerada em uma Rede Lógica de Markov (MLN). A MLN permite filtrar e garantir maior assertividade no reconhecimento da atividade. Os autores avaliam a eficácia da segmentação através de duas métricas, chamadas pureza e desvio de segmentos. Um segmento é perfeitamente puro (ou seja, seu valor de pureza é igual a 1) quando todos os seus eventos são rotulados com a mesma classe de atividade. A segunda métrica é calculada como a raiz quadrada média do erro

de segmentação em termos do número de segmentos inferidos. Além disso, os autores avaliam o impacto do método de segmentação através de Medida F para o RAH. Adotando os conjuntos de dados CASAS e SmartFaber, os autores obtiveram 0,76% como média de reconhecimento para todas as atividades. Os autores não utilizam aprendizagem de máquina, ou outra técnica para aprender sobre o comportamento individual de um usuário.

Finalmente, no trabalho (DÍAZ-RODRÍGUEZ *et al.*, 2014) os autores realizaram experimento utilizando uma base de dados conhecida, denominada CAD-120 (KOPPULA *et al.*, 2013). Utilizando ações capturadas por câmeras, os objetos de uso, ou *object affordances* e postura humana na ação de uso dos objetos são coletados. Essas informações definem eventos e atividades para cada residente. Para tanto, um método híbrido proposto utiliza aprendizagem de máquina, particularmente, o algoritmo k vizinhos mais próximos, ou *K-Nearest Neighbors* (k-NN), um algoritmo de aprendizado de máquina supervisionado para classificar as ações em suas respectivas atividades. A estratégia de segmentação definida em (DÍAZ-RODRÍGUEZ *et al.*, 2014) utiliza as informações obtidas pelo algoritmo de aprendizagem de máquina e armazena em uma estrutura de dados, denominada tabela de dispersão. Como resultado da consulta a tabela, diferentes atividades são recuperadas, pois, possuem ações semelhantes e filtros são utilizados em conjunto com uma ontologia difusa para reconhecer uma atividade.

A literatura em técnicas híbridas de segmentação dos fluxos de dados de sensores são comparados ao método híbrido proposto na Tabela 4.

A Tabela 4 apresenta aspectos relevantes em técnicas híbridas de segmentação de fluxos de dados de sensores aplicados ao reconhecimento de atividade humana. Dentro desses aspectos encontram-se, os conjuntos de dados, características dos dados coletados por sensores, tipo de processamento de evento, descrição da técnica baseada em dados, ou Algoritmo de Aprendizagem, e da técnica baseada em conhecimento, ou Tecnologia Semântica, além do uso de ontologia para anotação dos metadados de segmentos. Em (SFAR, 2019), os autores manipulam dados brutos (DSB), ou seja, dados de sensores implantados em objetos, como, por exemplo, sensor M003 ON, que corresponde a geladeira aberta, definindo eventos simples e uma ontologia para representação na detecção de atividades em uma janela estática.

Abordagens como (CIVITARESE *et al.*, 2019b; DÍAZ-RODRÍGUEZ *et al.*, 2014) utilizam eventos anotados como, objetos de uso, localização e postura humana, processando os eventos gradualmente (CIVITARESE *et al.*, 2018) ou consultando os eventos em estruturas de dados (DÍAZ-RODRÍGUEZ *et al.*, 2014) para definir uma janela dinâmica. Analisando as

Tabela 4 – Técnicas híbridas de segmentação de fluxos dados de sensores para reconhecimento de atividade humana. As colunas adotam: TS — Tecnologia Semântica; e OS — Ontologia de Segmentação. As linhas adotam: DSB, AP — Aprendizagem Probabilística, ODU — Objeto De Uso; PH — Postura Humana; L — Localização; SMO- Otimização Sequencial Mínima; PV - Perceptron Votado; FA - Florestas Aleatórias; e TD - Tabela de Decisão.

Estudos	Conjunto de Dados	Características	Processamento de evento	Algoritmo de Aprendizagem	TS	OS
Salguero et al.,2018	Kasteren, Singla e Ordoñez	DSB ODU+L	Simples	C4.5, OSM, PV, FA e TD	Inferência Semântica	Não
Sfar; Bouzeghoub, 2019	Aruba	DSB	Simples	Clusterização	Ontologia	Não
Civitarese et al., 2019	CASAS SmartFABER	ODU+L	Simples	Rede Markov	Inferência Semântica	Não
Diaz et al.,2014	CAD-120	ODU+PH	Simples	k-NN	Ontologia Difusa	Não
<b>SeAct</b>	<b>Kasteren e CAD-120</b>	<b>ODU+PH ODU+L</b>	<b>Complexo</b>	<b>k-NN</b>	<b>Inferência Semântica</b>	<b>Sim</b>

Fonte: Elaborado pela autora (2023).

técnicas baseadas em conhecimento, em (CIVITARESE *et al.*, 2018), a ontologia definida e suas restrições, são utilizadas na inferência de atividades, filtradas pelo algoritmo de MLN.

Em (DÍAZ-RODRÍGUEZ *et al.*, 2014), o algoritmo de aprendizagem aprende padrões de comportamento do usuário, e o segmento é definido por uma consulta aos eventos representados por uma estrutura de dados. A ontologia difusa é utilizada como filtro para as atividades detectadas nas etapas anteriores.

SeAct propõe a correlação entre eventos simples, processando eventos complexos, para obter uma janela dinâmica. O segmento é determinado pela duração de atividades inferidas por regras e raciocínio semântico. Para compor as regras, foi utilizado um algoritmo de aprendizagem. O método disponibiliza uma ontologia que permite a anotação de metadados de segmentos, úteis para as aplicações de reconhecimento de atividades.

Em (SALGUERO *et al.*, 2018) objetos de uso e sua localização são entradas para uma ontologia que combina conceitos e inferem novos conceitos utilizando as restrições da ontologia. Novos eventos podem ser inferidos e são úteis para algoritmos de aprendizagem de máquina utilizados no experimento realizado. SeAct propõe inferência baseada nas regras sobre eventos conhecidos. Para tanto, utiliza o resultado da aprendizagem de máquina para construção das regras.

As técnicas descritas estão anteriormente relacionadas as etapas necessárias para inferir os segmentos, desde a aprendizagem e classificação, até a sua escolha baseada em semântica, ou não. Ou seja, são técnicas baseadas na abordagem e recursos necessários para definir os segmentos. Segundo (SERPUSH *et al.*, 2022), também é possível definir a segmentação baseada em suas características em: janela baseada em atividade, baseada em tempo, dependente de sensor, extensão dependente do sensor e último estado do sensor.

### 3.2 Ontologias para Anotação Semântica de Fluxos de Dados

Na literatura, a maioria dos eventos obtidos por fluxos de dados de sensores são processados e segmentados com apoio de métodos e estratégias baseadas em dados e conhecimento. Em sistemas de RAH, esse processo de segmentação pode utilizar técnicas híbridas, aumentando sua complexidade devido à heterogeneidade de técnicas de análise e processamento. Ainda nesse cenário, a semântica é cada vez mais adotada para o objetivo de compartilhar metadados sobre sensores, e não anotam os fluxos de dados.

As ontologias para anotação semântica de fluxo são escassas, pois, geralmente a semântica é pesada para processar e não é ideal para Ambiente de Vida Assistida, onde os dados são atualizados com frequência. Outro desafio comum em diferentes abordagens que anotam fluxos de dados são a expressividade na anotação de dados, tamanho da persistência e eficiência na consulta (ELSALEH *et al.*, 2020).

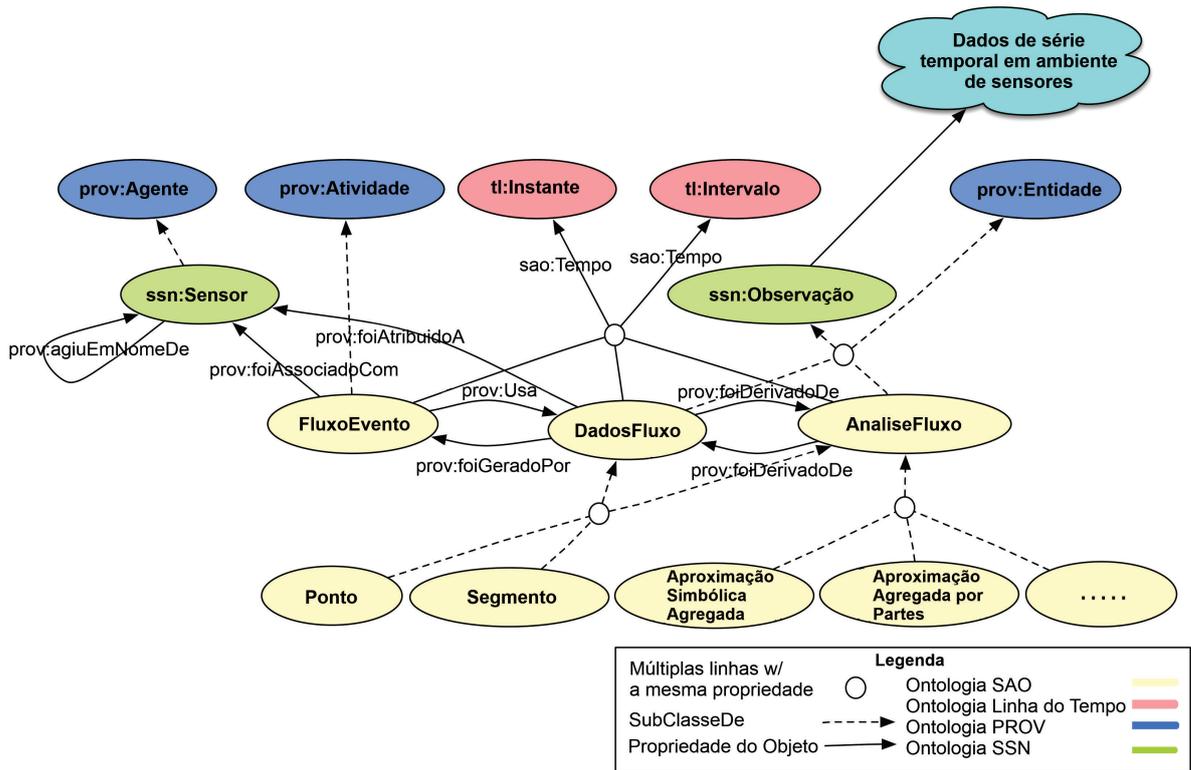
Nos últimos anos, alguns pesquisadores conceberam e aplicaram a ideia de modelos leves de informação no campo da Internet das Coisas, como o IoT-Lite (BERMUDEZ-EDO *et al.*, 2016) (Figura 11), e a ontologia *Semantic Sensor Network* (SSN) (COMPTON *et al.*, 2012), que estão centrados na representação em torno dos dispositivos. Para anotação de fluxos de dados em Internet das Coisas, foram encontradas na literatura as ontologias SAO (Stream Annotation Ontology) (KOLOZALI *et al.*, 2014) e IoT-stream (ELSALEH *et al.*, 2020).

A ontologia SSN (Figura 12) descreve sensores com suas propriedades, sistemas, implantações, estímulos e observações. O foco do IoT-Lite, SOSA e SSN são os dispositivos de detecção e descoberta de sensores. Portanto, essas ontologias não consideram anotação de metadados dos segmentos gerados pelos métodos de segmentação.

SAO (Figura 13) foi construído sobre algumas ontologias conhecidas para representar fluxos de dados IoT: TimeLine (RAIMOND, 2008), PROV-O (GARIJO, 2013), SSN e Event Ontology (RAIMOND, 2008).



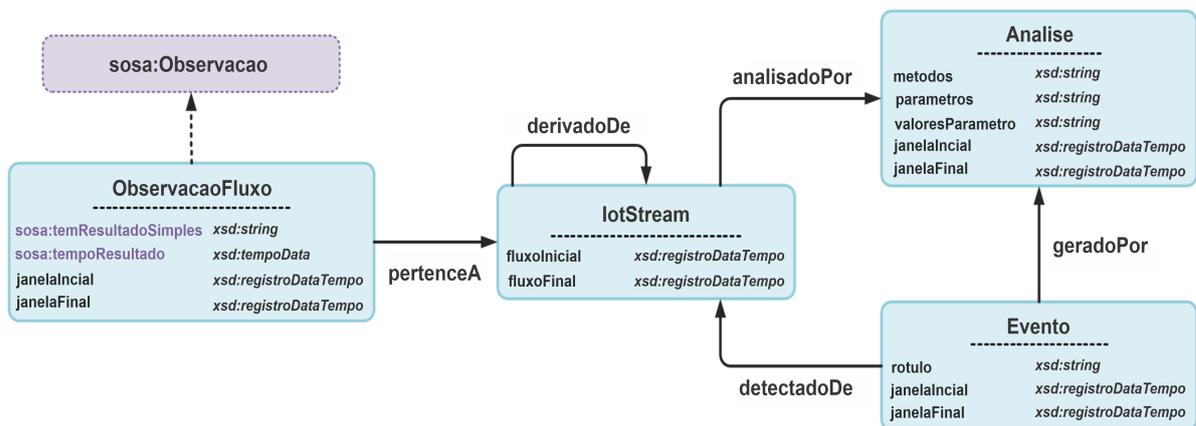
Figura 13 – SAO (Stream Annotation Ontology)



Fonte: Adaptado de (KOLOZALI *et al.*, 2014)

(para o fluxo de dados processados). Para fins de consulta e rastreamento, os autores também anexam metadados fora das observações do fluxo, como algoritmo aplicado e seus parâmetros com seus valores.

Figura 14 – Classes e propriedades IoT-Stream

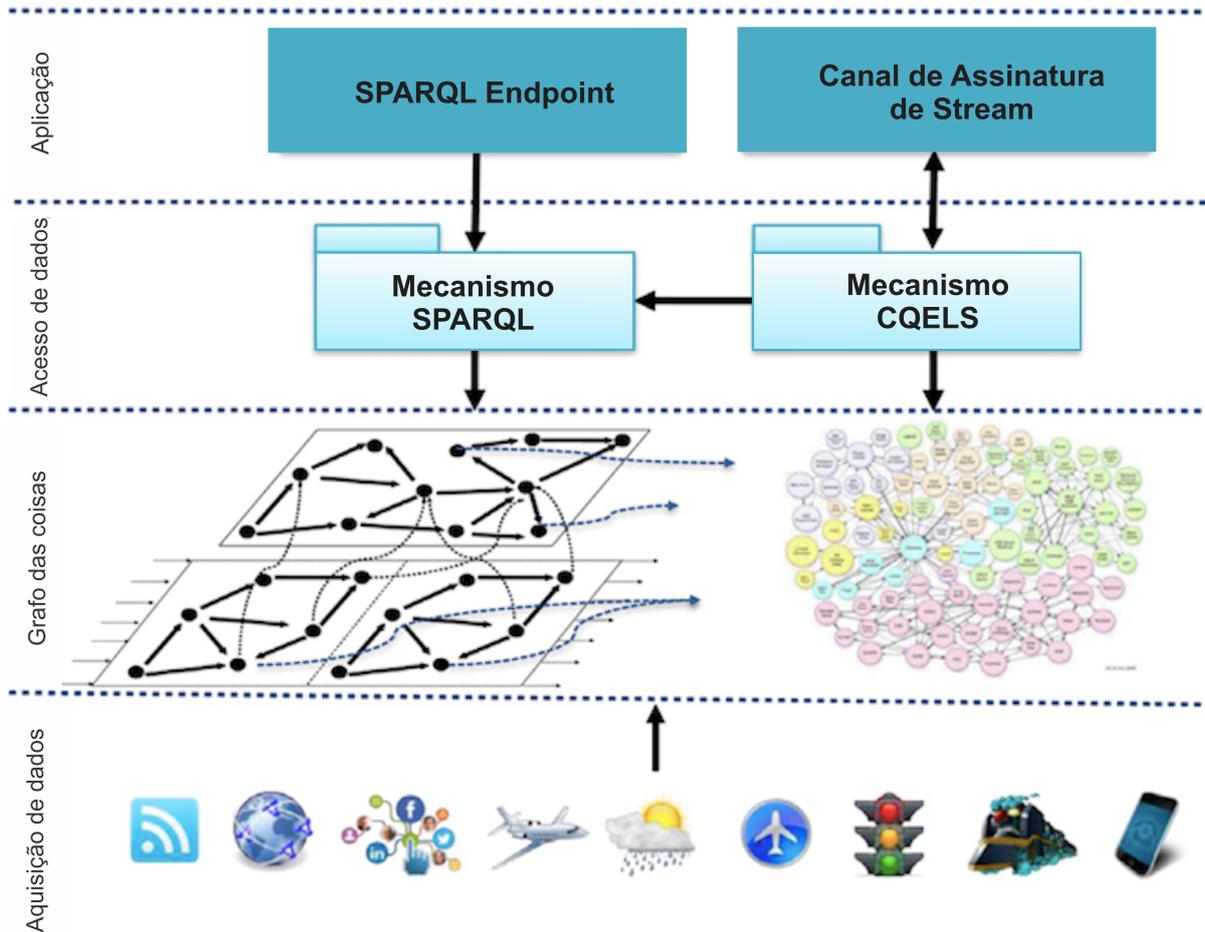


Fonte: Adaptado de (ELSALEH *et al.*, 2020)

Em (LE-PHUOC *et al.*, 2016) os autores apresentam um gráfico de coisas com anotações espaciais e temporais usando SSN e um caso de uso representando voos em um mapa para anotar fluxos. No entanto, os autores anotaram valores individuais, e não consideram a

tarefa de segmentação de dados. As ontologias mencionadas anteriormente poderiam ajudar na anotação do fluxo de eventos, mas não abordam conceitos sobre os segmentos, disponibilizando metadados necessários para consulta e rastreamento pelas aplicações.

Figura 15 – O grafo das coisas: Arquitetura em camadas



Fonte: Adaptado de (LE-PHUOC *et al.*, 2016)

SeRt é comparada as demais ontologias da literatura na Tabela 5.

Tabela 5 – Análise comparativa de ontologias para anotação de fluxos de dados de sensores

Ontologias	Leve	Representação	Anotação
IoT-Lite	Sim	Dispositivos	Dispositivo e serviço
SSN	Sim	Dispositivos	Sensores e Observação
SAO	Não	Fluxos	Segmento estático
IoT-Stream	Sim	Fluxos	Fluxos de dados processados
O grafo das coisas	Não	Fluxos	Fluxos de dados brutos
<b>SeRt</b>	<b>Sim</b>	<b>Fluxos</b>	<b>Segmentos dinâmicos</b>

Fonte: Elaborado pela autora (2023).

A Tabela 5 apresenta características encontradas nas ontologias. O tipo de modelagem, ou modelo leve refere-se aos modelos projetados na perspectiva de um modelo de informação simples, com poucos metadados, sendo assim considerados leves para o processamento em Ambientes de Vida Assistida, onde os dados são atualizados com frequência. A outra característica apontada entre as ontologias são os tipos de representação, alguns fornecem informações sobre os dispositivos e seu resultado, ou seja, o resultado de uma observação individual, ou sobre os fluxos de observações coletadas por sensores. Por último, foi destacado o tipo de anotação onde é possível demonstrar a necessidade da abordagem proposta. As anotações realizadas pelas demais ontologias abrangem dispositivos, segmento estático utilizando eventos simples ou fluxos de dados processados por métodos de aprendizagem de máquina cujo resultado são eventos obtidos e anotados em uma janela estática. Nenhum dos modelos anota os segmentos dinâmicos gerados por análise dos fluxos, anotando o intervalo de ocorrência entre os eventos para definição do segmento. Além disso, a adoção de diferentes técnicas de segmentação requer uma ontologia que descreve os metadados necessários. No Capítulo 4 definimos a proposta SeRt, que visa estender IoT-Stream para anotar os fluxos de dados. Contudo, SeRt tem objetivo de atender a necessidade de aplicações de RAH que exigem uma janela de tempo derivada por um método de segmentação.

A interoperabilidade entre sistemas é uma problemática que impulsiona a construção de ontologias para segmentação, pois, recursos heterogêneos, sejam sensores ou técnicas aplicadas na segmentação, precisam de representação para o consumo por aplicações na etapa de análise. Para descrever como essa representação ocorre a ontologia e exemplos de instanciação para uma aplicação de RAH podem ser encontradas no Capítulo 4.

## 4 SERT: ONTOLOGIA PARA ANOTAÇÃO DE SEGMENTOS

Este capítulo apresenta uma ontologia para representação dos metadados de segmentos resultantes da segmentação dinâmica de fluxos de dados de sensores. A Seção 4.1 apresenta as classes e propriedades da ontologia proposta. A Seção 4.2 descreve o processo de anotação. A Seção 4.3 fornece exemplos de anotações baseadas em técnicas de segmentação. Finalmente, a Seção 4.4 conclui este capítulo descrevendo a ontologia proposta.

### 4.1 Classes e Propriedades da ontologia SeRt

O objetivo dessa seção é apresentar a ontologia SeRt <sup>1</sup>, projetada para representar metadados de segmentos. SeRt estende o IoT-Stream (ELSALEH *et al.*, 2020) para anotar os fluxos de dados. Ontologias de anotação de fluxos são escassas (ELSALEH *et al.*, 2020) e a IoT-Stream é uma ontologia leve projetada para anotar dados de sensores e a análise envolvida na interpretação dos dados coletados por esses sensores. Ontologias leves fornecem a formalização mais simples que atende a tarefa em questão, tornando-se apropriadas para adaptações, atualizações e gerenciamentos em ambientes onde a escala e o desempenho são críticos (POLI *et al.*, 2010).

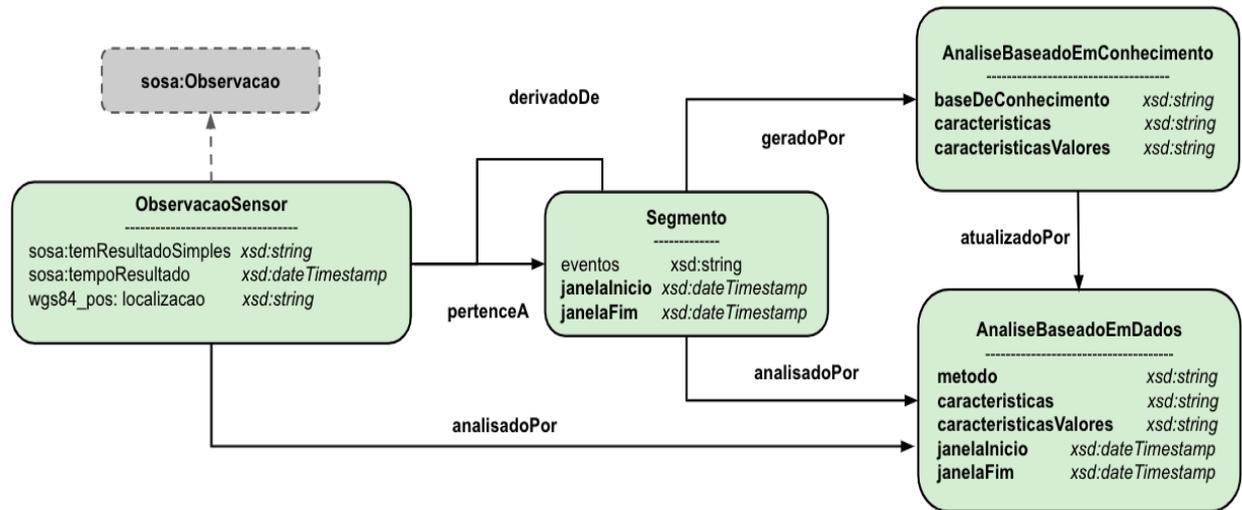
Ao contrário de IoT-Stream, SeRt anota metadados de segmentos dinâmicos resultantes de métodos de segmentação. Metadados como janelas de tempo, informações sobre o processo analítico e eventos que ocorrem no intervalo das janelas.

O vocabulário proposto foi concebido para atuar como uma representação entre os publicadores e consumidores de eventos segmentados, e pode ser aplicado desde a detecção de informações de sensores até a publicação. À medida que o número de sensores e dados aumenta, o tempo dedicado à anotação e consulta em ontologias tornou-se um gargalo no processamento em tempo real (ELSALEH *et al.*, 2020). Portanto, o uso de modelos leves, com um número mínimo de conceitos e relações entre eles, é suficiente para permitir consultas regulares e rastreamento de fluxos de dados, melhorando o tempo de processamento dos dados de sensores (ELSALEH *et al.*, 2020). Assim, cada observação em um fluxo é composta por apenas um valor, data e hora, localização (do sensor) e valor.

De acordo com a Figura 16, a ontologia consiste em classes e propriedades que descrevem os conceitos necessários sobre segmentos. O modelo se concentra na modelagem

<sup>1</sup> <https://github.com/amandadrielly/SeRt-Ontology>

Figura 16 – Classes e propriedades SeRt



Fonte: Elaborado pela autora (2023).

de observações de fluxos, segmento, sua análise e tecnologia semântica, que são descritos em cinco classes. Conforme ilustrado na Figura 16, a classe de interesse e consumo é a **ObservacaoSensor**. A observação do fluxo de eventos contém informações sobre o dado bruto, a data e hora registradas *timestamp* que mantém um registro do momento em que a observação foi capturada e a localização geográfica, quando aplicável.

A classe principal a que as outras classes se vinculam é denominada de **Segmento**. Essa abstração representa um fluxo de dados originado de uma fonte de dados de um Ambiente de Vida Assistida. Ele tem propriedades de anotação que capturam os eventos atuais dentro de uma janela de tempo fixa ou dinâmica que devem ser consumidas em tempo real pelos serviços de RAH. Essas propriedades de anotação incluem a janela inicial e a janela final dos eventos segmentados. Na classe Segmento, são apresentados metadados que permitem a anotação do ajuste dinâmico de segmento durante o processo de segmentação, incluindo a possibilidade de anotar metadados de diferentes técnicas de segmentação.

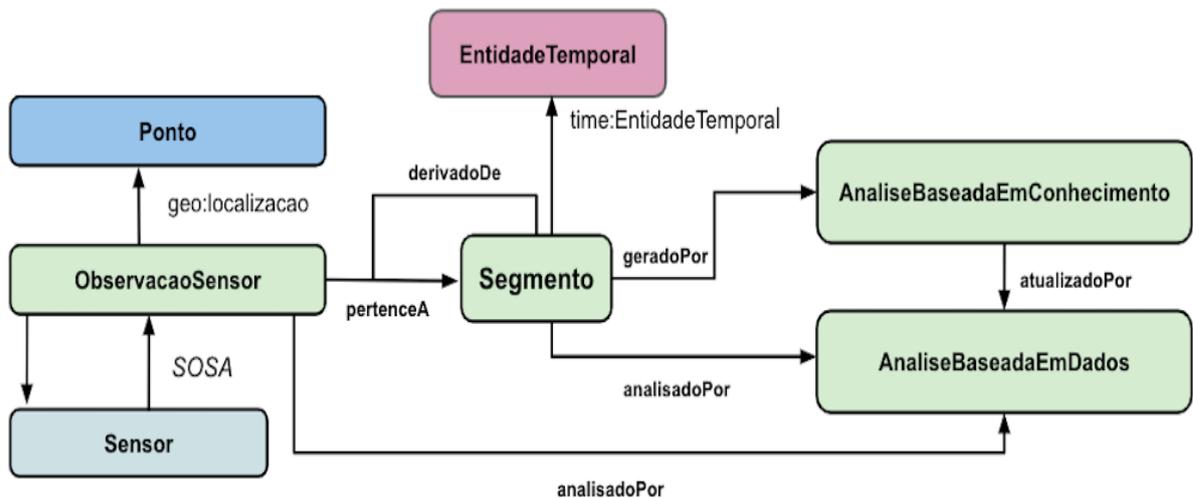
Para fins de consulta e rastreamento, o grafo de conhecimento gerado inclui metadados que descrevem as observações do fluxo de eventos, os algoritmos aplicados e seus parâmetros com valores e a tecnologia semântica utilizada.

A ontologia proposta reusa conceitos de diferentes ontologias conhecidas (Figura 17).

- A ontologia SOSA fornece uma classe que atende aos requisitos para captura de uma observação de sensores, sendo a classe *sosa:Observação* e suas propriedades de tipo de dados, *sosa:hasSimpleResult* e *sosa:resultTime*.

- Um recurso bastante utilizado pelos métodos de segmentação é a localização dos sensores dentro do Ambiente de Vida Assistida. Para tanto, a ontologia WSG84 foi adotada para fornecer um conjunto de conceitos básicos que representam a localização de uma entidade. O principal conceito de interesse é o `geo:Ponto` que contém propriedades geoespaciais (Latitude, Longitude e Altitude). Particularmente a propriedade `geo:localizacao`.
- Outro requisito é conseguir capturar o aspecto temporal de um segmento. Para anotar esse requisito a `time:TemporalEntity` da ontologia *Time Ontology* foi adotada.

Figura 17 – SeRt e o reuso das principais ontologias.



Fonte: Elaborado pela autora (2023).

A anotação utilizando SeRt resulta em um grafo de conhecimento que possibilita a navegação e consulta dos metadados. O conceito **Segmento** é utilizado como um nó raiz, que se conecta diretamente com os metadados mais relevantes no contexto das consultas relacionadas ao processo de segmentação. Essa abordagem simplifica as consultas, pois reduz a necessidade de navegação entre os nós.

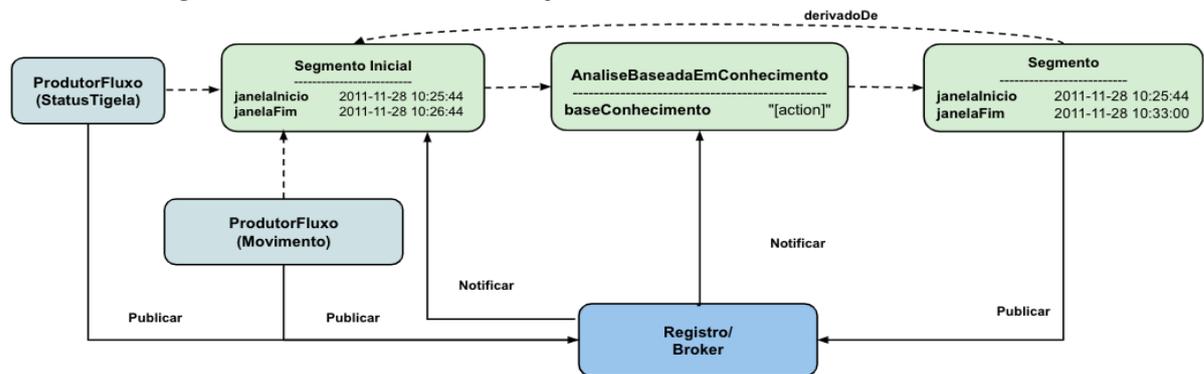
#### 4.2 Processo de Anotação usando SeRt

Os segmentos e os conceitos correlatos necessitam ser divulgados para os serviços e aplicações, incluindo os sistemas de RAH, que são consumidores desses metadados.

A Figura 18 ilustra o processo de anotação usando SeRt para segmentos resultantes de um método híbrido de segmentação. As setas tracejadas indicam o fluxo real dos dados, enquanto

as setas solidas representam o processo de publicação (i.e., tudo que precisa ser registrado em um sistema de publicação/assinatura) e notificação (i.e., tudo o que foi previamente registrado para ser notificado sobre alterações ocorridas em publicadores de um sistema de publicação/assinatura), que são orquestrados por um *broker* responsável pela troca de informações.

Figura 18 – Processo de anotação adotando SeRt.



Fonte: Elaborado pela autora (2023).

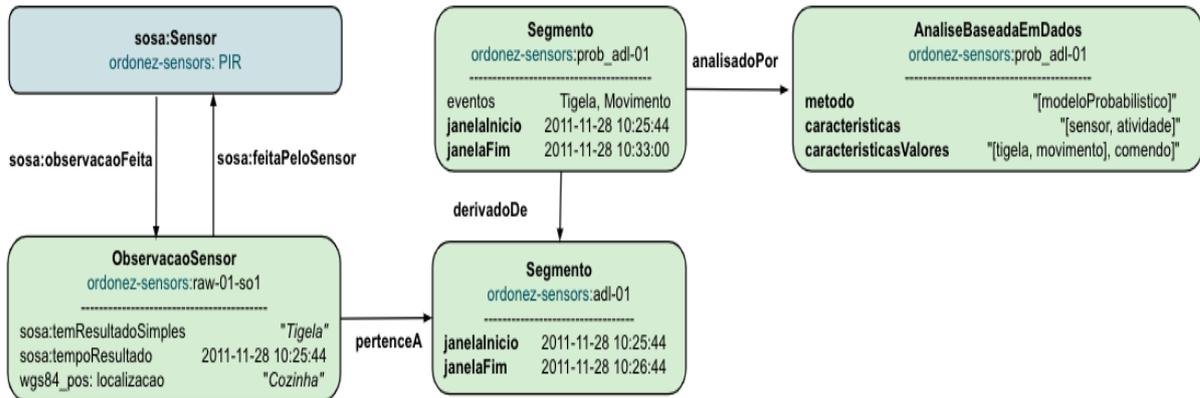
A ilustração do processo de anotação de segmento (Figura 18) emprega dois produtores para a publicação de observações de sensores, isto é, os eventos de utilização de uma tigela e o movimento capturado como postura. A classe **Segmento** é responsável por produzir o segmento inicial ao receber esses dois eventos no segmento atual. Além disso, a análise baseada em conhecimento recebe notificações advindas do *broker*. A análise utiliza o segmento atual para processar e anotar as características associadas à saída correspondente ao novo segmento. A propriedade **derivadoDe** é utilizada para rastrear os segmentos. Finalmente, o segmento pode ser publicado no *broker*, tornando o resultado disponível para os consumidores.

### 4.3 Exemplos de Anotação de Segmentos usando SeRt

Diferentes técnicas de segmentação podem utilizar SeRt. Para a técnica híbrida existe a necessidade de utilizar todas as classes definidas em SeRt. Isso ocorre pela necessidade de retratar os metadados da análise baseada em dados e baseada em conhecimento. Para ilustrar o uso da anotação de segmentos, três exemplos são apresentados para cada técnica de segmentação.

A Figura 19 exemplifica uma instância de SeRt que utiliza técnica baseada em dados. Os metadados da classe **Segmento** são gerados por meio do uso de *sosa:Sensor* e *sosa:observacaoFeita* que capturam os dados dos sensores. Nesse exemplo, a classe **Segmento** apresenta atributos que permitem a definição de uma janela inicial de 60 segundos para capturar as observações. Outras instâncias desses atributos podem ser derivados através de um processo

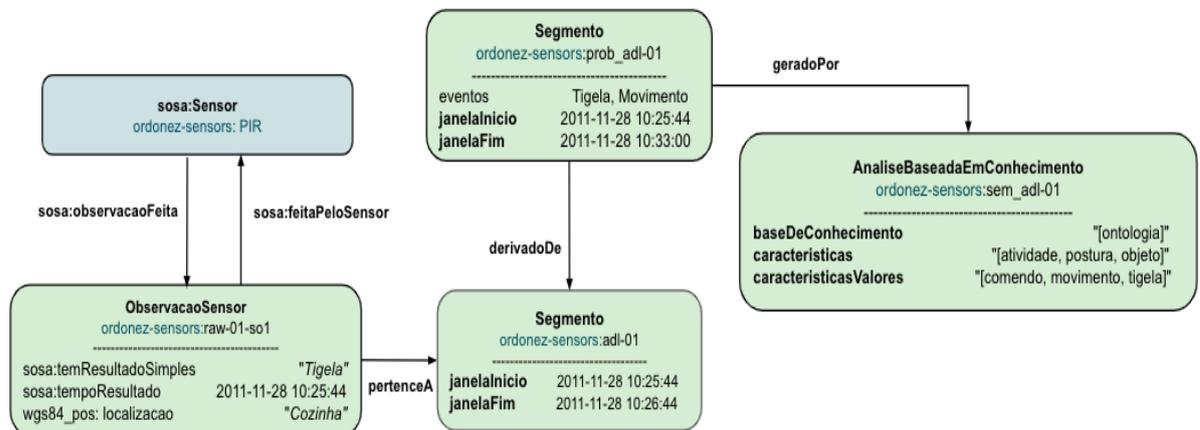
Figura 19 – Exemplo de anotação adotando SeRt para técnica baseada em dados.



Fonte: Elaborado pela autora (2023).

analítico que envolve um método probabilístico. A saída do processo analítico é o valor **comendo** que é a atividade inferida e seu segmento associado, que deve ser anotado pela ontologia. Eventos podem ser fornecidos para um mesmo segmento, indicando as prováveis atividades que estão ocorrendo.

Figura 20 – Exemplo de anotação adotando SeRt para técnica baseada em conhecimento.

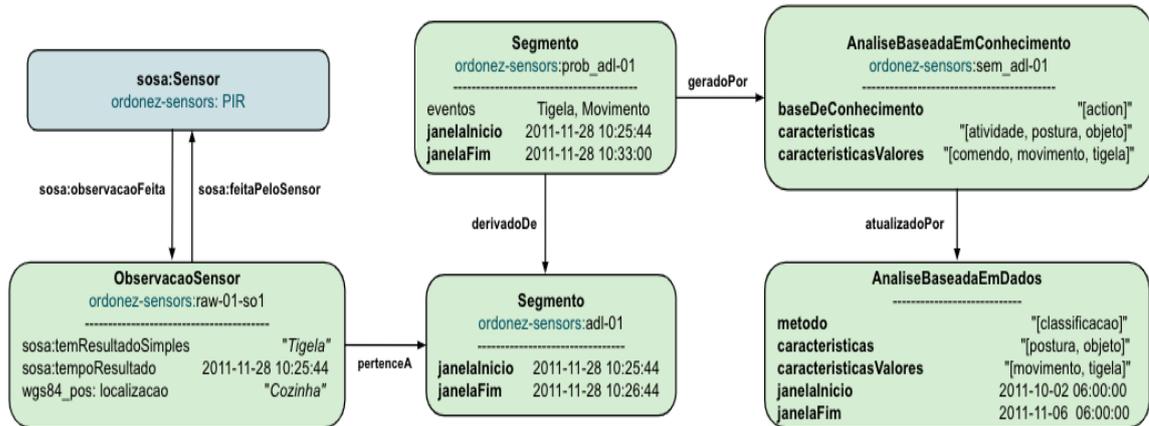


Fonte: Elaborado pela autora (2023).

Na Figura 20, é possível observar uma instância de SeRt utilizando técnica baseada em conhecimento. No exemplo, a classe **Segmento** possui atributos que permitem a definição de uma janela inicial de 60 segundos para capturar as observações. Outras instâncias desses atributos podem ser derivadas a partir de uma base de conhecimento, como por exemplo, uma ontologia. Características como objeto de uso, localização do sensor e atividade são encontradas na literatura e utilizadas para definir os metadados de SeRt.

Na Figura 21 é apresentada uma instância de SeRt utilizando a técnica híbrida. A classe **Segmento** possui atributos que permitem a definição de uma janela inicial de 60 segundos

Figura 21 – Exemplo de anotação adotando SeRt para técnica híbrida.



Fonte: Elaborado pela autora (2023).

para capturar as observações. Outras instâncias desses atributos podem ser derivadas a partir de uma base de conhecimento, como uma ontologia. A classe **AnaliseBaseadaEmConhecimento** define o atributo **características**, com as informações necessárias para derivar o novo segmento. Nesse exemplo de instância Figura 21, a ontologia é atualizada com o resultado da Classificação. Como a atualização da ontologia é realizada *offline*, os dados de entrada correspondem aos dias que o residente foi monitorado, aspecto essencial para obtenção dos padrões de comportamento do residente.

#### 4.4 Considerações Finais

Neste capítulo, foi proposta a ontologia SeRt para anotar segmentos oriundos da segmentação dinâmica de fluxo de dados de sensores. A principal novidade da ontologia SeRt é a possibilidade de rastrear e consultar os recursos que derivam os segmentos, incluindo os segmentos de janelas ajustadas dinamicamente, anotando os recursos necessários para representar as técnicas de segmentação encontradas na literatura. Ao contrário dos trabalhos relacionados, SeRt suporta a natureza incerta dos segmentos derivados por eventos de sensores e os explora para definir o tamanho da janela, o que chamamos de segmentação não estática ou variável. Além disso, a ontologia consegue representar o conhecimento prévio e suas características. A validação proposta pode ser encontrada no Capítulo 6 dessa tese.

A seguir, um resumo das principais contribuições do capítulo:

- SeRt, uma ontologia leve para anotar metadados de segmentos resultantes da segmentação dinâmica de fluxos de dados de sensores.

- Grafo de conhecimento gerado pela anotação que permite consulta e rastreamento por sistemas de RAH.

## 5 SEACT: MÉTODO HÍBRIDO DE SEGMENTAÇÃO DE FLUXOS DE DADOS DE SENSORES

Esse capítulo aborda o método de segmentação semântica de fluxos de dados de sensores em AAL, denominado SeAct. SeAct é proposto no escopo desta tese com objetivo de fornecer segmentação de fluxos de dados de sensores, utilizando técnicas baseadas em dados e conhecimento em um método híbrido para manipulação de segmento (i.e, janela de tempo), útil para sistemas de RAH.

SeAct emprega a combinação de eventos simples, denominado de processamento de eventos complexos, para inferir atividades, obter suas durações e definir o segmento correspondente. Esse método corresponde as questões de pesquisa 1 e 2 levantadas no Capítulo 1 dessa tese. Além disso, SeAct possui características como, segmento baseado em atividade e extensão de segmento dependente do sensor (SERPUSH *et al.*, 2022), tornando-se um método relevante para o tópico de pesquisa.

Neste capítulo, a Seção 5.1 discute a visão geral do método. Na Seção 5.2, são apresentadas camadas e arquitetura de atuação do método em uma infraestrutura IoT. As Seções 5.3 e 5.4 abordam as etapas offline e online do método SeAct. Finalmente, na Seção 5.5, encontra-se a discussão desse capítulo.

### 5.1 Visão geral

As informações fornecidas pelos AAL são analisadas através de um ciclo de aquisição, processamento e análise. Na etapa de processamento de dados, os fluxos de dados produzidos pelos sensores são adquiridos sob uma sequência de registros de detecção, assim, toda detecção é considerada um evento.

Na etapa de processamento, a tarefa de segmentação de dados é responsável por dividir a sequência de registros em janelas que podem apresentar uma duração fixa, ou dinâmica. O tamanho da janela é um problema crucial para os mecanismos de análise de dados, pois, capturam os eventos que ocorreram em um conjunto de segmentos individuais, fornecendo as informações necessárias para o RAH. Além do RAH, outros domínios podem recorrer à segmentação como a detecção de anomalia, sistemas autoadaptativos ou análises de trajetórias.

Na Seção 2.2, são discutidas algumas abordagens da literatura que adotam o tamanho de segmento fixo e dinâmico. Os métodos que utilizam o tamanho de janela fixo, muitas vezes adotam mecanismos de aprendizagem probabilística para propor uma segmentação dinâmica

após um período de aprendizado. Outras abordagens que fornecem uma segmentação dinâmica semântica utilizam ontologia e consultas semânticas para recuperar a duração das atividades através dos eventos que se encontram em uma janela de tempo (SFAR; BOUZEGHOUB, 2019), mas não realizam associação de eventos simples, como, por exemplo, objetos de uso e postura humana, para desambiguação de atividades. O resultado desse esforço é a obtenção de um segmento mais preciso, ou mais próximo da ocorrência atual.

Quando o tamanho do segmento é escolhido incorretamente, eventos necessários para o reconhecimento, podem não participar do segmento, como também, eventos irrelevantes podem participar do segmento, impactando na acurácia do reconhecimento. Para exemplificar, quando um residente utiliza um objeto como uma xícara e esse objeto pertence à atividades como limpando, comendo ou preparando refeição, essas atividades possuem durações diferentes, resultando na definição de um segmento inadequado.

Embora estudos atuais, como relatados na Seção 2.2, permitam o RAH com medidas elevadas de acurácia e precisão, os autores adotam diferentes abordagens para filtrar atividades reconhecidas por técnicas de segmentação. Assim, um problema desafiador é melhorar a capacidade de reconhecimento de atividades em casos onde um único sensor pode participar de diferentes atividades.

Os objetos, ou seja, sensores implantados em objetos, são eventos simples, contudo, quando esses eventos são associados, como, por exemplo, com a postura humana no momento em que realiza a atividade, podem fornecer a oportunidade de raciocínio e decisão sobre uma atividade. Por exemplo, o residente utiliza a xícara e a postura humana em uma ação que denota que está derramando o líquido em seu interior, o que pode resultar em uma atividade de limpeza, diferentemente, quando o usuário utiliza a xícara para beber, denotando uma atividade bebendo.

Ainda sobre a Seção 2.2, é possível concluir que os métodos híbridos de segmentação são os melhores candidatos a serem empregados no processamento e análise de dados de sensores em AAL. Com base nessa análise e para superar a questão de desambiguação e variabilidade de comportamento dos usuários de trabalhos anteriores, um novo método híbrido para a segmentação semântica de fluxos de dados de sensores é proposto.

O método SeAct possui uma arquitetura que integra técnicas de segmentação de fluxos de dados de sensores em uma nova abordagem híbrida que processa eventos complexos, fornecendo segmentos de fluxos de dados de sensores para as aplicações. O método é projetado para ser empregado em diferentes aplicações, desde que um conjunto de dados de monitoramento

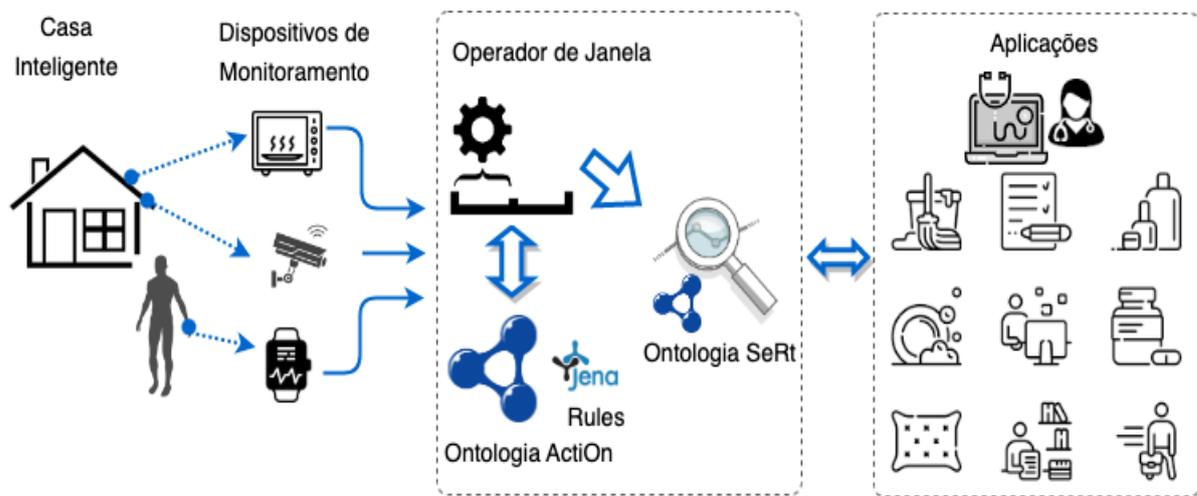
do usuário possa ser fornecido e demais requisitos definidos nas seções seguintes sejam atendidos. O método considera seis entidades (vide Figura 22).

1. *Casa Inteligente*. A casa inteligente é o AAL que possui os dispositivos de monitoramento. Muitas vezes implantados em objetos ou em locais, como um cômodo da casa.
2. *Dispositivos de Monitoramento*. São dispositivos miniaturizados equipados com biossensores, microcontroladores e transmissão de dados sem fio. Esses dispositivos podem ser incorporados a objetos como micro-ondas, copo, tigela e talheres, podem ser fixos em lugares da casa, como câmeras, vestuário ou usados no corpo como acessórios, por exemplo, um relógio inteligente. Eles podem capturar o uso através da pressão, quando, por exemplo, utilizado um copo, alternando seu estado para ON, quando em uso, ou OFF, quando não está em uso. Também capturam posturas humanas e movimentos, com uso das câmeras e sinais fisiológicos do paciente, como pressão arterial, taxa de açúcar no sangue, frequência cardíaca, condições de sono, padrões respiratórios, entre outros, quando incorporados diretamente a partes do corpo humano. Os dados coletados serão enviados para um serviço, onde ficam disponíveis para análise por parte das aplicações e serviços.
3. *Operador de Janela*. A proposta combina um método de aprendizagem de máquina supervisionado, que aprende o comportamento do usuário nas atividades diárias, e um método baseado em semântica que utiliza inferência semântica para raciocinar baseado no comportamento aprendido, inferindo atividades, a fim de permitir a manipulação da janela de tempo.
4. *Ontologia ActiOn*. Uma ontologia núcleo com as informações sobre sensores, eventos e atividades é definida para armazenar os fluxos de dados coletado e permitir a aplicação de regras, previamente definidas. As regras estabelecem que eventos podem inferir atividades.
5. *Ontologia SeRt*. Essa ontologia anota os segmentos, além de outras informações,

geradas pelo operador de janela para fins de representação e rastreabilidade pelas aplicações.

6. *Aplicações*. São aplicações que utilizam os eventos coletados e segmentados em suas tarefas de análise para, por exemplo, reconhecer atividades.

Figura 22 – Visão geral do SeAct integrado a um AAL.



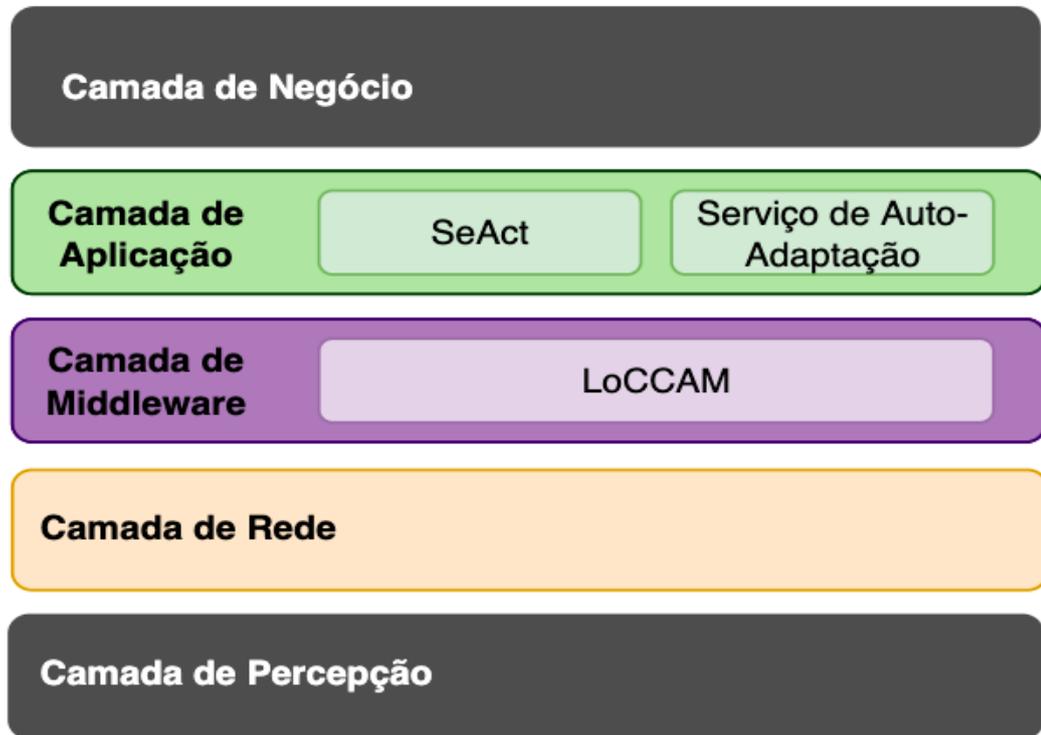
Fonte: Elaborado pela autora (2023).

## 5.2 Camadas e Arquitetura

SeAct é um método proposto para atuar na camada de aplicação de uma infraestrutura IoT, conforme representado na Figure 23. Na camada de percepção e de rede os dados de sensores são coletados e transportados para o *middleware Loosely Coupled Context Acquisition Middleware (LoCCAM)* (MAIA *et al.*, 2013), que pode ser utilizado como plataforma de suporte à interação com os sensores dispostos no ambiente físico. O SeAct manipula eventos detectados pelos sensores, ou seja, as informações de baixo nível não são responsabilidades do método. Assim, a infraestrutura deve ser responsável por capturar, transportar e provê suporte a manipulação dos dados que devem ser entregues como eventos ao SeAct. O método foi inicialmente proposto e validado para melhoria do reconhecimento de atividades, com objetivo de impactar essa melhoria em aumento de precisão e acurácia. Contudo, serviços de auto adaptação, como, por exemplo, o SUCCEED (JUNIOR *et al.*, 2018), podem utilizar SeAct para detectar situações, por exemplo, em detecção de anomalias, para adaptar objetos inteligentes.

O método é híbrido e está dividido em duas etapas (vide Figure 24), sendo elas,

Figura 23 – SeAct aplicado a uma infraestrutura IoT.

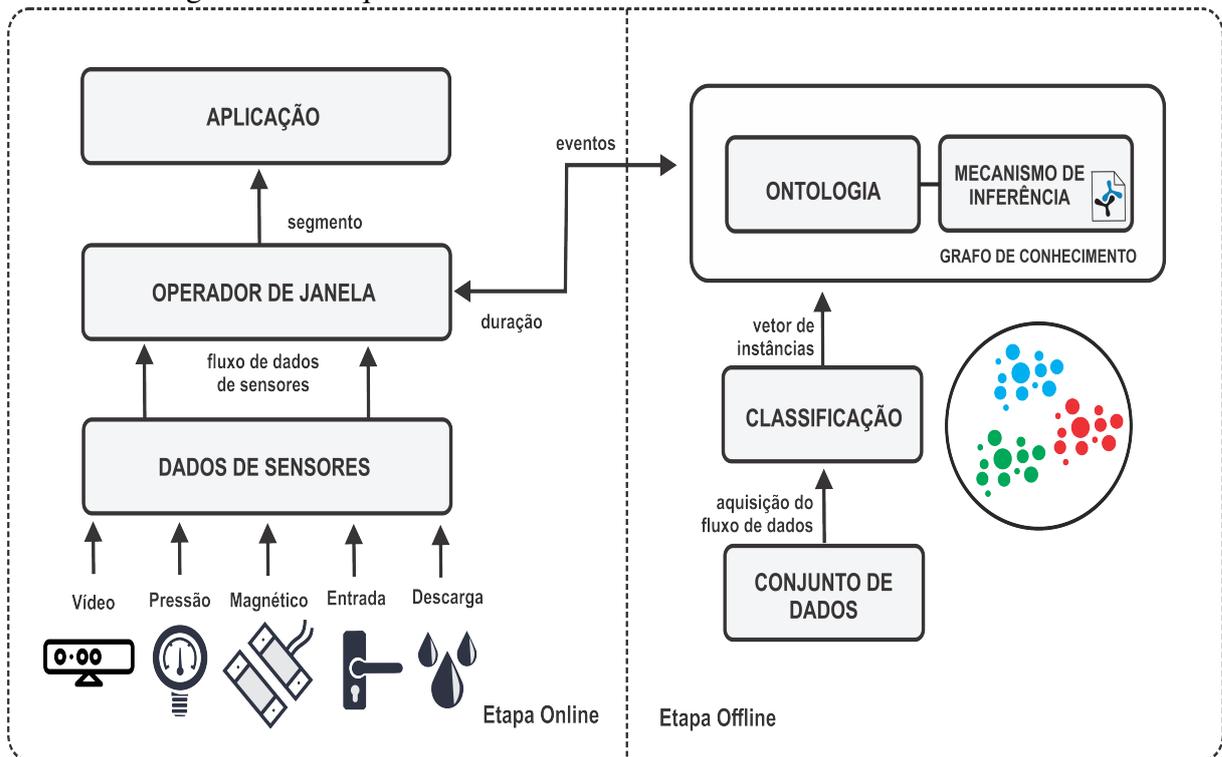


Fonte: Elaborado pela autora (2023).

*offline* (vide Seção 5.3) e *online* (vide Seção 5.4). Na Seção 5.3, uma técnica baseada em dados é necessária para aprender o comportamento dos usuários. Um conjunto de dados de monitoramento de um residente é adquirido, e esses dados são utilizados como entrada para o processamento que usa aprendizagem de máquina. O resultado da aprendizagem é utilizado para gerar regras de inferência semântica úteis para detecção dos eventos e inferência de atividades. Na Seção 5.4, uma técnica baseada em conhecimento, particularmente, um Grafo de Conhecimento, ou *Knowledge Graph* (KG) é gerado. O KG utiliza a ontologia instanciada com os eventos capturados e raciocínio sobre as regras definidas para definir a atividade e consequentemente sua duração, posteriormente utilizada pelo algoritmo de adaptação da janela de tempo.

Na Figura 24, o método de segmentação SeAct se inicia na etapa *offline*, adquirindo um conjunto de dados de padrões de comportamento e atividades dos indivíduos. Esse conjunto de dados é necessário para treinar o modelo de classificação utilizado para aprender o comportamento do residente por um período e posteriormente reconhecer atividades (Seção 5.3). Se o AAL é uma casa inteligente, é possível denominar esse conjunto de dados como pertencente aos residentes. O resultado desse processo é utilizado pelo método para definir regras de inferência semântica que serão utilizadas na etapa *online* em conjunto com a ontologia definida. Na etapa de processamento *online* é realizada a segmentação semântica de fluxos de dados de sensores

Figura 24 – Arquitetura SeAct.



Fonte: Elaborado pela autora (2023).

em janelas de tempo com base no conhecimento fornecido pelo grafo de conhecimento. Os segmentos produzidos são anotados pela ontologia SeRt (descrita em detalhes no Capítulo 4), desde os sensores utilizados até o método de análise, tornando assim, os segmentos publicáveis e disponíveis para consumo pelas aplicações. Nas subseções a seguir, detalhes do método proposto são apresentados, destacando a necessidade de uma abordagem híbrida que é capaz segmentar fluxos de dados de sensores. Também são definidos experimentos, demonstrando como os segmentos produzidos são úteis para um ambiente de saúde inteligente, particularmente para sistemas de RAH.

### 5.3 Etapa Offline

Ao longo desta seção, detalhes da etapa *offline* do método SeAct (Figure 24) são discutidos. Essa seção discute a importância de adquirir eventos simples, coletados pelo monitoramento dos residentes para construir regras semânticas que devem inferir atividades e sua duração. A etapa está dividida em subetapas: (1) Aquisição do Conjunto de Dados de Sensores, (2) Classificação, (3) Ontologia ActiOn e (4) Regras de inferência semântica.

### 5.3.1 Aquisição do Conjunto de Dados de Sensores

Inicialmente, o residente ou participante das ações, deve ser monitorado por um período. Não foi encontrado estudo conhecido que defina a quantidade de amostras e como isso impacta no resultado. Alguns trabalhos citados na motivação dessa tese, demonstram que conjuntos de dados públicos encontram-se disponíveis, sobre diferentes domínios, para que a comunidade se beneficie, aprofundando conhecimentos na área. Assim, a aquisição dos fluxos de dados de sensores utilizando conjunto de dados públicos ou sintéticos devem executar o Protocolo 1 (Figure 25), para disponibilizar os dados para a subetapa seguinte (vide Subsubsubseção 3.2.1.2).

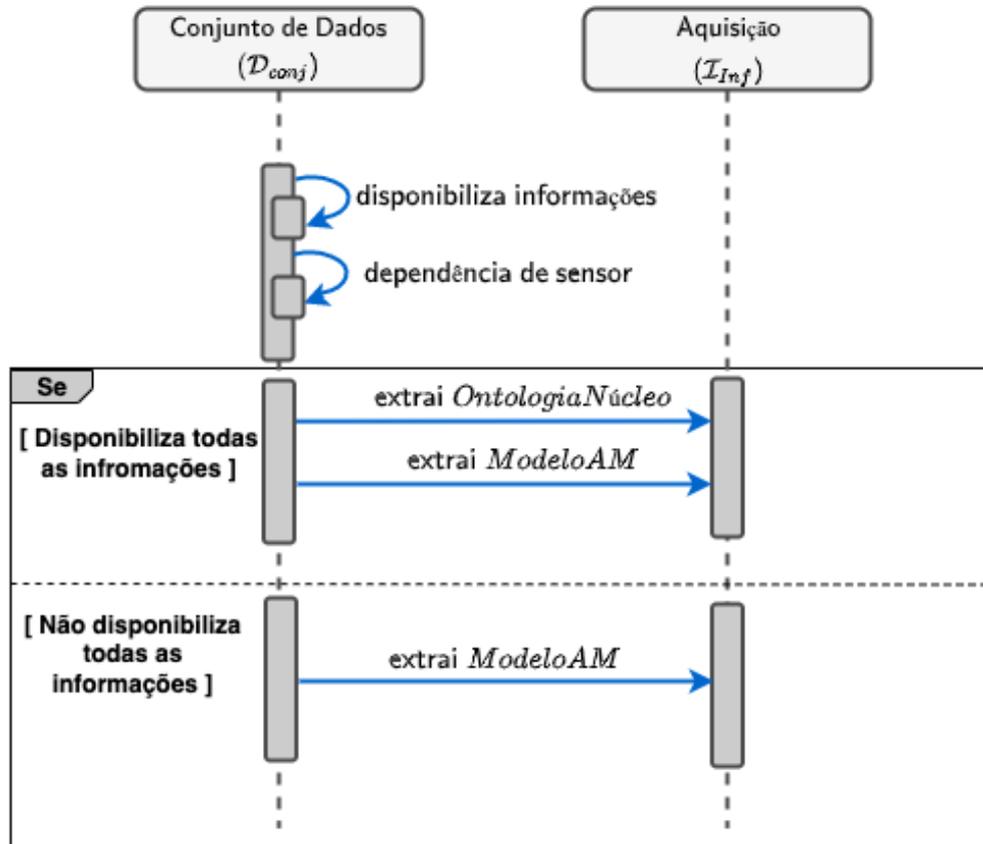
#### Protocol 1 - AQUISIÇÃO DE FLUXO

- **Objetivo:** *adquirir o fluxo de dados obtidos através do monitoramento das ações de um residente.*
- **Participantes:** *o conjunto de fluxo de dados de sensores  $\mathcal{D}_{conj}$ , operando como local de armazenamento, e a aquisição SeAct  $\mathcal{S}_{inf}$  que coleta as informações necessárias para o método.*

#### **Passos:**

1. *Assumindo que  $\mathcal{D}_{conj}$  disponibiliza informações sobre os participantes da coleta, sensores, eventos e demais atributos relacionados aos eventos, como tempo de duração, ou timestamp.*
2. *Assumindo que os sensores de um mesmo dispositivo, como câmera, ou de dispositivos diferentes, podem adquirir fluxos em sequência sobre uma ação.*
3. *A aquisição SeAct extrai  $\mathcal{S}_{inf}$  do conjunto de dados sobre informações como usuário, ou Pessoa monitorada e sensores utilizados na coleta. Adicionando essas informações na Ontologia ActiOn (Subsubsubseção 3.2.1.3). Devido a indisponibilidade dessas informações por parte de alguns conjuntos de dados, o registro pode não acontecer.*
4. *A aquisição SeAct extrai  $\mathcal{S}_{inf}$  do conjunto de dados sobre os eventos, como, por exemplo, a postura humana e o objeto de uso no momento de uma ação como, pegar uma tigela. Os eventos devem conter o atributo timestamp. Adquirindo as informações necessárias para a classificação (Subsubsubseção 3.2.1.2).*

Figura 25 – Fluxo de trabalho da subetapa de aquisição do conjunto de dados de sensores.



Fonte: Elaborado pela autora (2023).

Como estudo de caso no domínio de RAH conjuntos de dados como RGB-D CAD-120 (KOPPULA *et al.*, 2013; LAI *et al.*, 2011) e Kasteren (KASTEREN *et al.*, 2008) participam do experimento. São conjuntos de dados públicos e populares que fornece informações sobre fluxos de dados de sensores e se enquadram nos requisitos do Protocolo 1 (Figura 25).

Na Figura 26, é possível observar algumas atividades reconhecidas através das ações dos residentes. Através de dados de uma câmera RGB-D, foram extraídas posturas corporais dos usuários que aparecem na frente do sensor, bem como a localização 3D dos objetos na cena. O dispositivo selecionado para esta tarefa é a câmera *Kinect* da *Microsoft*, que oferece profundidade e imagens RGB da cena. Cada um das posturas detectadas corresponde a uma sequência de imagens obtidas pela câmera, neste caso uma sequência das posturas corporais do usuário e dos objetos que participam da atividade. O corpo do usuário é representado em um conjunto de quinze pontos 3D (cabeça, pescoço, tronco e ombros esquerdo e direito, cotovelos, quadris, mãos, joelhos e pés) por meio da câmera e do *middleware* utilizado.

Para entender relações entre as variáveis, particularmente, a relação entre os eventos

Figura 26 – Amostras de imagens RGB do conjunto de dados CAD-120.



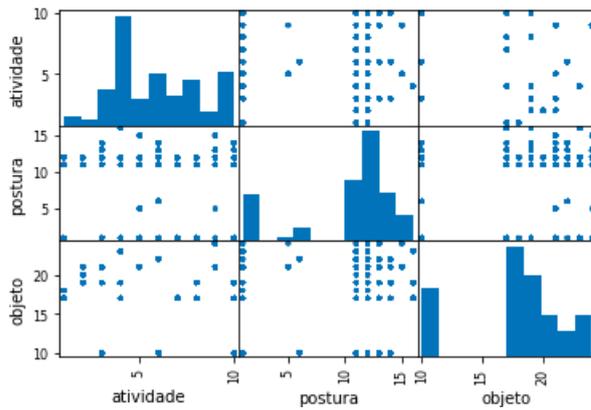
Fonte: Adaptado de (KOPPULA *et al.*, 2013)

de postura e os objetos envolvidos na cena, é necessário investigar como essa relação pode impactar na definição de ações e consequentemente no reconhecimento de atividades. Para tanto, instâncias para cada usuário do conjunto de dados em uma matriz de dispersão, também chamado gráfico de dispersão é disponibilizada. Na Figura 27 é possível observar as atividades, posturas e objetos de uso de cada usuário, disponíveis no conjunto de dados *Cornell Activity Dataset (CAD)-120*.

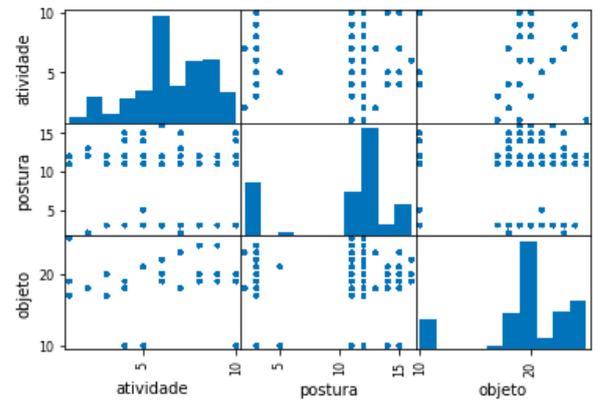
A Figura 27 apresenta a relação entre atividade, objeto e postura para quatro usuários do conjunto de dados CAD-120. Para visualizar essa matriz de dispersão foi necessário normalizar as diferentes atividades, posturas e objetos utilizados por cada usuário durante o monitoramento realizado. Para os usuários um, dois e três, é perceptível que as posturas 10 até 15 pertencem a várias atividades, dificultando o processo de reconhecimento da atividade utilizando somente a postura, contudo. Ainda é possível observar que eventos associados, como posturas e objetos de uso, tornam a tarefa de separar viável. Para o usuário quatro, isso se reflete nas posturas de 5 a 10. Quando ocorre uma mudança em um objeto, provavelmente uma nova atividade está em curso.

"Nesse passo Joana precisa ser monitorada pelo período de três meses, por exemplo. O resultado desse monitoramento é um conjunto de dados com os objetos que Joana utiliza e a posição em que ela se encontra quando utiliza esses objetos. As atividades

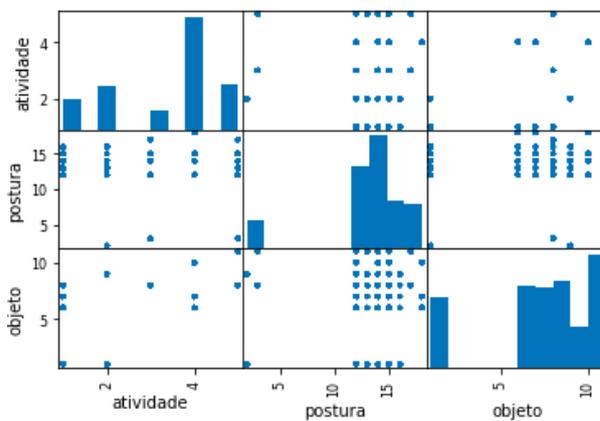
Figura 27 – Matriz de dispersão para usuários do conjuntos de dados CAD-120.



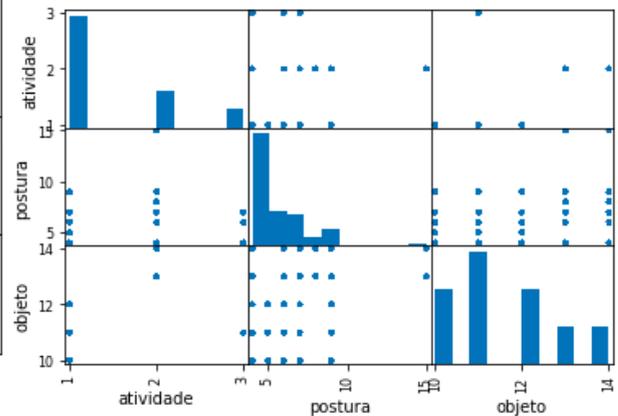
(a) Usuário 1.



(b) Usuário 3.



(c) Usuário 4.



(d) Usuário 5.

Fonte: Elaborado pela autora (2023).

podem ser anotadas manualmente, quando um especialista define que atividades ocorrem no cenário. Por exemplo, quando Joana utiliza a tigela e está sentada na mesa, dentre as atividades que podem ocorrer, o especialista defini a atividade de comer. Esse conjunto com eventos, por exemplo, objetos e posição e sua atividade correspondente são entrada da etapa offline de SeAct."

### 5.3.2 Classificação

Métodos baseados em aprendizado de máquina exploram dados históricos e aplicam diversas abordagens como probabilidade, estatística e álgebra linear para treinar os modelos de modo a realizar previsões sobre o futuro, utilizando um comportamento histórico associado a características do problema (AKBAR *et al.*, 2019).

O método híbrido proposto usa aprendizado de máquina como mecanismo para

aprender o comportamento do usuário. O monitoramento de ações de um usuário pode ser utilizado, por exemplo, detecção de anomalias, onde, quedas, Acidente Vascular Cerebral (AVC), insuficiência cardíaca, etc. O reconhecimento de atividades pode auxiliar nas AVD, utilizando objetos inteligentes, ou auxiliando na detecção de anomalias. A tomada de decisão por equipes médicas ou cuidadores nesses casos deve ser imediata.

É necessário monitorar o participante por um período para aprender um conjunto de informações relevantes sobre as ações diárias em um AAL. Essa amostra significativa de fluxos de dados de sensores é armazenada em conjuntos de dados, como descritos na seção anterior. O modelo de aprendizado de máquina proposto, aprende as ações de cada participante individualmente. É possível destacar que o modelo utiliza mais de umas características relacionadas a ação. Ou seja, eventos simples devem ser adquiridos para uma mesma ação. Por exemplo, em uma aplicação de detecção de quedas, os eventos obtidos pelo sensor de câmera e pelo acelerômetro poderiam ser utilizados para definir ações dos usuários dentro de um domínio de quedas. Outro exemplo, apresenta uma sequência de eventos relacionadas à postura humana ao abrir e fechar o micro-ondas. É possível identificar ações ocorrendo em conjunto com o objeto de uso, por exemplo, micro-ondas. As ações atômicas não denotam uma atividade como comer, mas várias ações são necessárias para permitir esse reconhecimento.

Após a aquisição de fluxo de dados de sensores (Subsubsubseção 3.2.1.1) o Protocolo 2 (Figura 28) deverá ser executado.

## **Protocol 2** — APRENDIZADO DE EVENTOS, AÇÕES

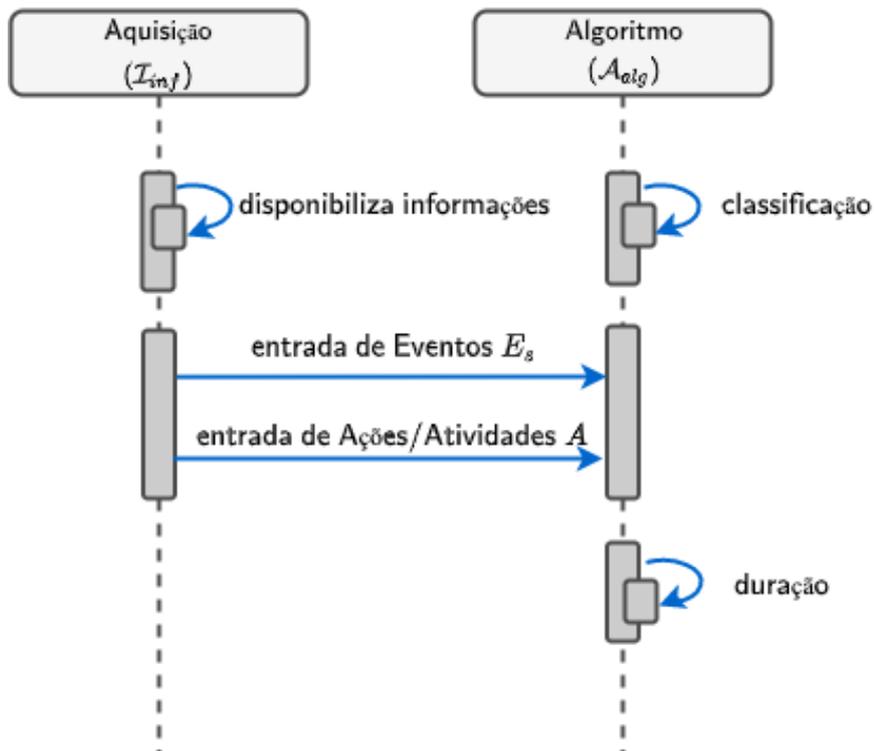
- **Objetivo:** obter um modelo de Aprendizado de Máquina (AM) utilizando os eventos e ações adquiridos.
- **Participantes:** a aquisição SeAct  $\mathcal{S}_{inf}$ , responsável pela coleta e pré-processamento das informações sobre os eventos e ações, e o algoritmo de aprendizagem  $\mathcal{A}_{alg}$ , definido para classificar eventos e ações.

### **Passos:**

1. Assumindo que  $\mathcal{S}_{inf}$  disponibiliza as informações relacionadas aos eventos e ações, por exemplo. Com seus respectivos atributos, como tempo de duração, ou timestamp.
2. Assumindo que o algoritmo de aprendizado de máquina  $\mathcal{A}_{alg}$  possibilita a classificação e o aprendizado de eventos e ações de um usuário.

3. Como entrada para  $\mathcal{A}_{alg}$ , tem-se  $\mathcal{I}_{inf}$ , os eventos relacionados a mesma ação, que ocorram em sequência ou não. Em  $\mathcal{I}_{inf}$  eles são definidos como parte das características utilizadas para inferir uma ação.
4. Como entrada para  $\mathcal{A}_{alg}$ , tem-se  $\mathcal{I}_{inf}$  as ações, que em o estudo de caso são eventos relacionados as atividades.
5. O timestamp ou duração é utilizada pelo método para segmentação, também deve ser extraído de  $\mathcal{I}_{inf}$  e adicionado a saída do  $\mathcal{A}_{alg}$ .

Figura 28 – Fluxo de trabalho da subetapa de classificação



Fonte: Elaborado pela autora (2023).

O SeAct explora a melhoria da tarefa de segmentação adotando a extensão de janela dependente de sensor (SERPUSH *et al.*, 2022). Portanto, é necessário comparar o método com trabalhos que se enquadram no Protocolo 2 (Figura 28). Além disso, foram explorados eventos simples, que coletam as informações adquiridas pelos sensores, processando-as como eventos complexos. Os trabalhos, em sua maioria, não utilizam eventos gerados pelos sensores como extensão de janela dependente de sensor. Contudo, alguns estudos demonstram resultados promissores quando aplicam essa dependência, por exemplo, (DÍAZ-RODRÍGUEZ *et al.*, 2014).

Um algoritmo de aprendizagem supervisionada é usado para classificar atividades pertencentes a um determinado conjunto de dados com base nos eventos monitorados. Esta classificação é executada assim que um novo conjunto de dados é fornecido e visa aprender o comportamento individual dos residentes.

"Nesse passo o conjunto de dados sobre o comportamento de Joana é utilizado como conjunto de treinamento para os algoritmos de aprendizagem de máquina. Como resultado dessa etapa um modelo de classificação é obtido e será útil para anotar novos conjuntos de dados de monitoramento de Joana. O modelo, ou seu vetor de instâncias são entrada para criação das regras semânticas, Seção 5.3.4."

Para classificar as atividades com base na postura humana e nos objetos de uso, o trabalho <sup>1</sup> (DÍAZ-RODRÍGUEZ *et al.*, 2014) utiliza o conjunto de dados RGB-D CAD-120 e disponibiliza o código com resultado da classificação, utilizando o algoritmo k-vizinhos mais próximos(k-NN) (ZHANG, 2016). Em (DÍAZ-RODRÍGUEZ *et al.*, 2014), o conjunto de dados RGB-D CAD-120 (KOPPULA *et al.*, 2013; LAI *et al.*, 2011) é utilizado por um algoritmo de série temporal para aprender a sequência de posturas adotadas pelos usuários e as posições dos objetos em relação às ações, extraíndo assim essas informações através de câmeras. O método selecionado para esta tarefa foi a aproximação agregada por partes (PAA) (KEOGH *et al.*, 2001). Esses resultados são utilizados como *baseline* em um experimento que compara os resultados da segmentação utilizando o método de (DÍAZ-RODRÍGUEZ *et al.*, 2014) e SeAct.

Na Tabela 6 é possível observar as atividades e sua descrição.

Tabela 6 – Descrição semântica das atividades utilizadas no estudo de caso.

Atividade	Conceito Semântico	Descrição
Preparando cereal	cereal	Pegar a caixa de cereal, a tigela e o leite (abra-os) e despeja os dois.
Tomando medicamento	medicamento	Pegar a caixa de remédios do armário, pegar o frasco, comer a pílula e beber água
Cozinhando no micro-ondas	cozMicroondas	Pegar o recipiente de comida ou utensílios de cozinha, coloque no micro-ondas e retire
Limpando objetos	limpando	Limpe os objetos (micro-ondas com um pano)
Fazendo refeição	comendo	Comendo uma refeição na mesa

Fonte: Adaptado de (DÍAZ-RODRÍGUEZ *et al.*, 2014)

<sup>1</sup> <https://github.com/NataliaDiaz/HumanActivityRecognitionFuzzyDescriptionLogics>

Para uma comparação justa, k-NN e distância Euclidiana foram adotados para aprendizagem em SeAct. O IBk Weka <sup>2</sup> é o algoritmo implementado em SeAct. A principal vantagem desse algoritmo é que ele se adapta imediatamente à medida que novos dados de treinamento são coletados, sem a necessidade de ajustar parâmetros complexos. Como os conjuntos de dados nesse cenário de RAH tem poucas características, utilizando o k-NN existe pouca complexidade computacional para classificar novas amostras. Em outro momento, também são adotados eventos que incluem objetos e localização para comparação com a estratégia de (SALGUERO *et al.*, 2018). Para exemplificar o uso do k-NN, temos como entrada objetos de uso (e.g, copo, tigela e micro-ondas), como também, posturas (e.g, sentado, em pé e movimentando). Além disso, temos atividades anotadas para esses eventos simples, assim, para eventos como copo e sentado, podemos encontrar a atividade comendo. O algoritmo treina com algumas amostras para que seja capaz de classificar atividades para novas amostras.

### 5.3.3 *Ontologia ActiOn*

Nessa subetapa uma ontologia deve ser considerada para definir os conceitos necessários para aplicações ou serviços, definindo conceitos e relacionamentos necessários.

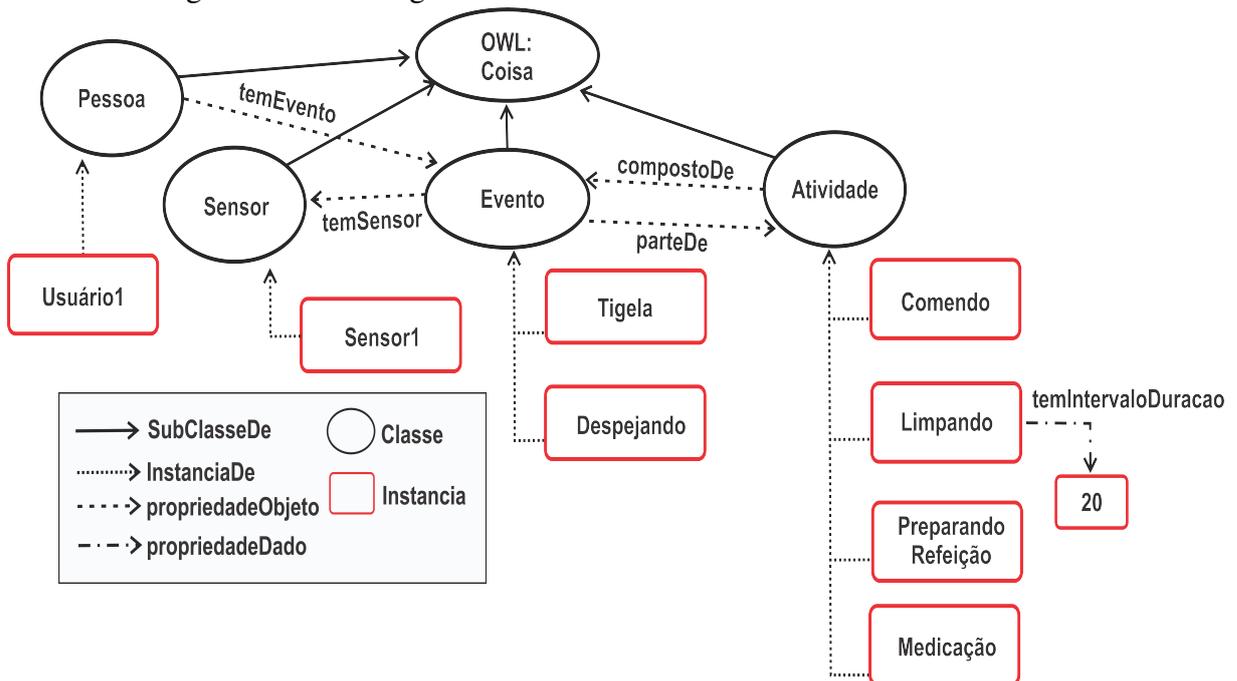
Os Ambientes de Vida Assistida englobam informações sobre seus participantes, sensores e valores de observações que são úteis para as aplicações. Contudo, esse cenário exige uma troca de informações através de uma infraestrutura de rede de comunicação entre os serviços, considerando um volume de dados (ELSALEH *et al.*, 2020), que deve ser tratado para minimizar os possíveis gargalos entre coleta e transmissão. Diante desse aspecto, uma ontologia núcleo (i.e., ontologia que define os termos centrais de um domínio específico), precisa ser definida para garantir que esses aspectos sejam atendidos. Para tanto, ActiOn foi definida. Essa ontologia representa conceitos relevantes para as aplicações de RAH.

A ontologia deve possuir um T-Box, descrevendo os conceitos relacionados ao domínio de aplicação. No estudo de caso, ActiOn (Figura 29), foi projetada, utilizando a ferramenta Protégé (PROTÉGÉ, 2008), para representar semanticamente as informações fornecidas pelo modelo de aprendizagem. Para povoar a ontologia com os fluxos de dados, Apache Jena foi adotado. Jena dispõe de uma estrutura de software livre para linguagem Java, fornecendo uma Application Programming Interface (API) para extrair dados e povoar ontologias.

Para exemplificar, foram adicionadas instâncias com informações relacionadas às

<sup>2</sup> <https://weka.sourceforge.io/doc.dev/weka/classifiers/lazy/IBk.html>

Figura 29 – Ontologia ActiOn com instâncias.



Fonte: Elaborado pela autora (2023).

atividades, eventos, sensores e pessoa. Inicialmente, a ontologia contém quatro classes principais (Atividade, Sensor, Evento e Pessoa), quatro propriedades de objetos principais (temEvento, compostoDe e parteDe) e uma PropriedadeDados (temValor, temIntervaloDuracao). As classes Activity e Evento são respectivamente o domínio e o intervalo de compostoDe, uma propriedade inversa de parteDe, onde o domínio é a classe Evento e o intervalo a classe atividade. A propriedade de dados temValor depende da classe Evento com um valor do tipo *String* que representa o valor do evento, por exemplo, o uso do objeto tigela enquanto o residente despeja um líquido.

Apesar de estudos definirem ontologias prévias que descrevem eventos, atividades e até sensores, a ontologia ActiOn relaciona eventos que fazem parte de uma atividade, onde, mais de uma atividade pode corresponder a pelo menos um dos eventos descritos, assim como, metadados, pessoa e sensores que detectaram determinado evento. Além disso, a PropriedadeDados(temValor) é necessária para vincular os eventos complexos que podem inferir uma atividade.

### 5.3.4 Regras de Inferência Semântica

É possível definir regras semânticas para representar e inferir conhecimento utilizando a ontologia ActiOn. O modelo utilizado pelas regras é o T-Box da ontologia e as

informações obtidas pela saída do algoritmo de aprendizagem de máquina que são entrada para a construção das regras. Em nossos experimentos, esse comportamento se refere ao uso de eventos como objetos, postura humana, localização e atividades (Subsubsubseção 3.2.1.2).

Após a aquisição do fluxo de dados de sensores (Subsubsubseção 3.2.1.1), a construção do classificador e o desenvolvimento da ontologia ActiOn, as regras de inferência podem ser definidas, onde o Protocolo 3 (Figura 30) deverá ser executado.

### **Protocol 3** — DEFINIÇÃO DAS REGRAS

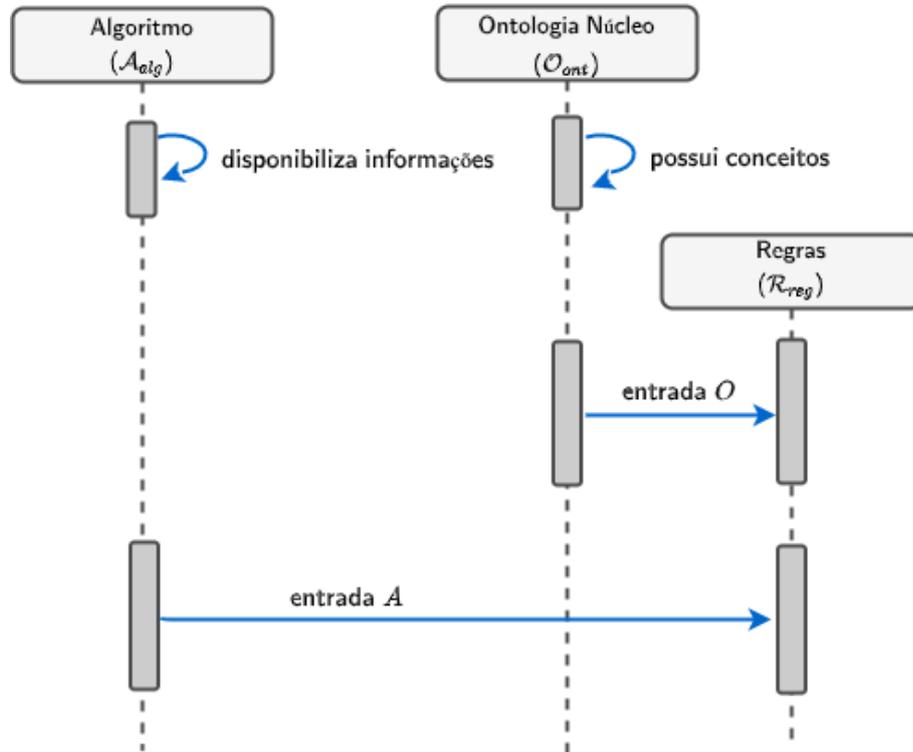
- **Objetivo:** obter um conjunto de regras semânticas.
- **Participantes:** o conjunto de regras  $\mathcal{R}_{reg}$ , o classificador  $\mathcal{A}_{alg}$ , responsável pela aprendizagem dos eventos e atividades e a ontologia ActiOn  $\mathcal{O}_{ont}$ , definida para representar conhecimento em um domínio de aplicação.

**Passos:**

1. Assumindo que  $\mathcal{A}_{alg}$  aprende as informações relacionadas ao domínio de aplicação.
2. Assumindo que  $\mathcal{O}_{ont}$  possui conceitos e seus relacionamentos definidos para o domínio de aplicação.
3. Como entrada para  $\mathcal{R}_{reg}$ , apresenta-se  $\mathcal{O}_{ont}$ , utilizada pelo mecanismo de raciocínio definido, para representar o conhecimento.
4. O resultado de  $\mathcal{A}_{alg}$  produz a entrada para construção das regras.

O conjunto de regras é atualizado conforme saída do algoritmo de classificação. Para tanto, o algoritmo 1 foi proposto. Para inferir novos fatos é necessário utilizar raciocínio com regras, baseado na lógica de predicados de primeira ordem ou LD para tirar conclusões a partir de uma sequência de declarações (premissas) derivadas de regras predefinidas (KRÖTZSCH *et al.*, 2012). As ferramentas de software que executam raciocínio com regras são conhecidas como mecanismos de raciocínio ou raciocinadores. Os raciocinadores lidam com vocabulários *Resource Description Framework* (RDF) e *Ontology Web Language* (OWL) e inferir fatos a partir de dados semânticos e ontologias com base em regras predefinidas. Motores de raciocínio como Jena (JENA, 2020), HermiT (HERMIT, 2020) e Fact++ (FACT++, 2020) são baseados em diferentes linguagens de regras e têm suporte para ontologias, OWL e implementam suas próprias sintaxes de regra. O raciocinador Apache Jena foi adotado para o algoritmo 1. Jena dispõe de

Figura 30 – Fluxo de trabalho da subetapa de regras de inferência semântica



Fonte: Elaborado pela autora (2023).

uma estrutura de software livre para linguagem Java, fornecendo uma *Application Programming Interface* (API) para extrair dados obtidos de arquivos gerando grafos de conhecimento RDF.

---

**Algoritmo 1:** Algoritmo para Construção de Regras

---

**Entrada:** Ontologia  $O$ , Eventos  $E$ , Atividade  $A$   
 Construir regras  $R$

**início**

$R \leftarrow Null$ ;

**para** cada evento  $e_i$  **faça**

$R \leftarrow addEventos()$ ;

**fim**

**para** cada evento  $e_i$  **faça**

$R \leftarrow dependenciaTempo()$ ;

**fim**

$R \leftarrow addAtividade()$ ;

**para** cada evento  $e_i$  **faça**

$R \leftarrow addRelacao()$ ;

**fim**

retorna  $R$ ;

**fim**

---

O Algoritmo 1 cria a variável responsável por construir a regra (Linha 1). Posteriormente, para cada evento dado, ele instancia a regra adicionando uma consulta SPARQL que utiliza os conceitos da ontologia. A relação entre a pessoa (residente), os eventos com seu valor e tempo relacionado são descritos (Linhas 2–3) usando a função addEventos. Em seguida, o algoritmo utiliza a função dependenciaTempo para conferir se os eventos ocorrem na duração da atividade (Linhas 4 e 5). A próxima etapa é relacionar as instâncias de Atividade com suas instâncias de eventos, onde através de uma variável a regra de equivalência é definida. (Linhas 6-10). Finalmente, o algoritmo 1 vincula cada instância de evento adicionada a atividade, usando o objeto de propriedade compostoDe e parteDe.

Na Tabela 7 a seguir, um exemplo do uso de regras utilizados pela abordagem em um exemplo de inferência da atividade comendo que recebe dois eventos, o objeto copo e a postura ou posição do usuário, movimentando.

Tabela 7 – Exemplo de Regra de Inferência em SeAct.

Regra 1	<pre>[RegraComendoRefeicao1: (?usuario ACTION:temEvento ?event1), (?event1 rdf:type ACTION:Evento), (?event1 ACTION:temValor "<b>copo</b>"), (?event1 ACTION:tempoRelacionado ?tempo1), (?tempo1 ACTION:temValor ?tval1), (?usuario ACTION:temEvento ?event2), (?event2 rdf:type ACTION:Evento), (?event2 ACTION:temvalor "<b>movimentando</b>"), (?event2 ACTION:tempoRelacionado ?tempo2), (?tempo2 ACTION:temValor ?tval2), makeTemp(?atividade) → (?atividade rdf:type ACTION:atividade), (?usuario ACTION:temAtividade ?atividade), (?atividade ACTION:temValor "<b>comendo</b>"), (?atividade ACTION:compostoDe ?event1), (?event1 ACTION:parteDe ?atividade), (?atividade ACTION:compostoDe ?event2), (?event2 ACTION:parteDe ?atividade), ]</pre>
---------	-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

Fonte: Elaborado pela autora (2023).

As regras SeAct seguem a estrutura que define-se na Tabela 7, onde as instâncias, eventos (objetos e postura) com suas atividades associadas são definidos em um passo de aprendizagem de máquina anterior cujo resultado é utilizado como entrada para o construtor de regras 1. É importante observar que esse processo tem vantagens, pois permite atualização dinâmica de regras sem nenhum requisito externo. Além disso, o método torna-se flexível, considerando as diferentes rotinas dos residentes. As regras definidas são apresentadas brevemente no Apêndice

A dessa tese.

## 5.4 Etapa *Online*

Na etapa *online*, conforme apresentado na Figura 24, existe uma subetapa de operação de janela. Essa subetapa permite que os eventos sejam processados, resultando em janelas dinamicamente ajustáveis. Os segmentos gerados são anotados para posterior publicação e consumo pelas aplicações e serviços, pela subetapa de anotação.

### 5.4.1 Operador de Janela

O Operador de Janela utiliza o fluxo de dados de sensores coletados, que deve popular uma ontologia, possibilitando o raciocínio das regras de inferência semântica definidas. A inferência produzida por regras deve ser utilizada para escolha do tamanho da janela, ou segmento. O Operador de Janela é definido conforme o Protocolo 4 (Figura 31).

#### Protocol 4 — OPERAÇÃO DE JANELA

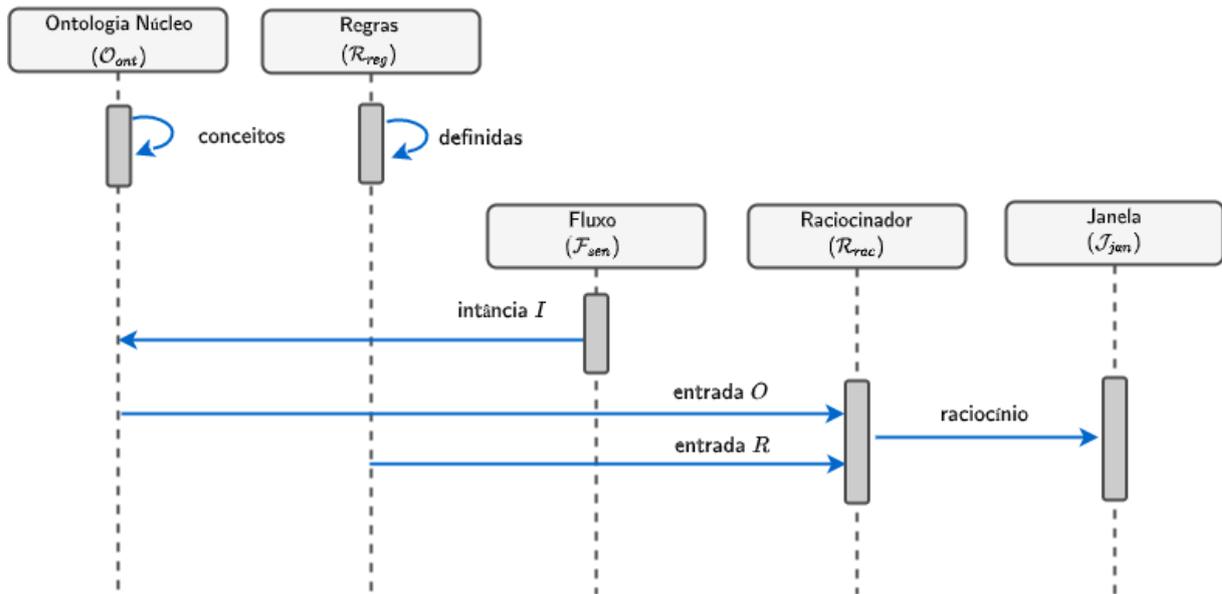
- **Objetivo:** definir janelas, ou segmentos de acordo com o resultado da inferência semântica da atividade para obter sua duração.
- **Participantes:** Fluxo de Dados de Sensores  $\mathcal{F}_{sen}$ , a ontologia ActiOn  $\mathcal{O}_{ont}$ , responsável por armazenar as instâncias para o mecanismo de raciocínio semântico  $\mathcal{R}_{rac}$ , as regras de inferência semântica  $\mathcal{R}_{reg}$  e o Operador de Janela  $\mathcal{J}_{jan}$  que disponibiliza os segmentos gerados.

**Passos:**

1. Assumindo que  $\mathcal{O}_{ont}$  disponibiliza informações relacionadas aos conceitos relacionados ao domínio de aplicação.
2. Assumindo que  $\mathcal{R}_{reg}$  estão definidas.
3. Assumindo que  $\mathcal{O}_{ont}$  armazena os eventos adquiridos pelo  $\mathcal{F}_{sen}$  em tempo real. Ou seja, os eventos são instâncias de  $\mathcal{O}_{ont}$ .
4. O  $\mathcal{R}_{rac}$  utiliza  $\mathcal{R}_{reg}$  e  $\mathcal{O}_{ont}$  para raciocinar e inferir conhecimento, utilizando eventos simples para definir eventos complexos.
5. O resultado de  $\mathcal{R}_{rac}$  produz o conhecimento necessário para definir  $\mathcal{J}_{jan}$ . Por exemplo, a inferência de atividades de um residente utilizando eventos simples, pode

ser utilizada para capturar a duração da atividade e possibilitar o ajuste da janela dinamicamente.

Figura 31 – Fluxo de trabalho da subetapa de operador de janela



Fonte: Elaborado pela autora (2023).

Em SeAct foi proposto o algoritmo Operador de Janela 2 para recuperar eventos do fluxo de dados de sensores e reconhecer atividades para extrair sua duração, utilizada para definição do segmento.

De acordo com (SFAR; BOUZEGHOUB, 2019), uma sequência de eventos pode ser representada como  $E_1, E_2, \dots, E_n$ , onde  $E_i$  se refere ao  $i^{\circ}$  evento capturado por sensores e cada evento do sensor é codificado no modelo de (data, hora, valorEvento). O objetivo desse processamento é dividir os fluxos de eventos em janelas de tempo com tamanho  $s$ . Para cada bloco,  $s$  é escolhido dinamicamente usando o Algoritmo 2 operador de janelas.

Para o Algoritmo 2 um tamanho da janela de tempo estática de 60 segundos é definido. Posteriormente, o algoritmo segue extraindo os eventos no fluxo de dados durante o tamanho da janela de tempo definida, usando a função leituraOnline (Linha 4). Os valores capturados pelos sensores são validados para extração de suas características, ou seja, qual objeto tem aquele sensor implantado (linha 5). Após isso os eventos são inseridos na ontologia (linha 6) para posterior aplicação das regras que geram as atividades relacionadas, usando a função aplicarRegrasAtividades (linha 7). Vale ressaltar que o experimento utiliza os dois primeiros

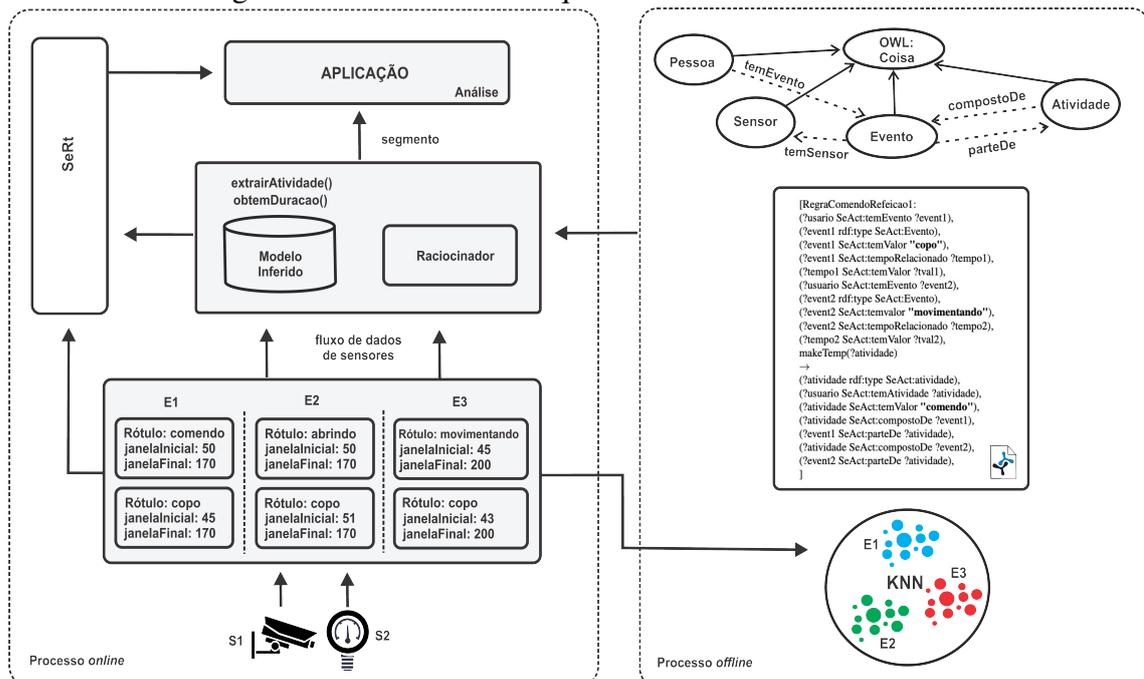
**Algoritmo 2:** Algoritmo Operador de Janela**Entrada:** Ontologia O, Regras R, Fluxo de dados FD

Segmento s

**início***resAtividades* ← Null;*intervalo* ← 60;**enquanto** *FD* ≠ Null **faça**    *sensores* ← *leituraOnline*(*FD*, *intervalo*);    *eventos* ← *validacao*(*sensores*);    *inserindoEventos*(*eventos*, O);    *aplicarRegrasAtividades*(O, R);    *resAtividade* ← *extrairAtividade*();    *s* ← *obtemDuracao*(*resAtividade*);**fim**retorna *s*;**fim**

eventos para estipular a janela. O algoritmo para o loop quando eventos são incluídos, em relação a alguma regra definida (Linhas 9-11). Em outras palavras, o algoritmo extrai as atividades que resultaram de alguma regra definida. Após a verificação, em caso positivo, a atividade é adicionada ao conjunto de possíveis atividades *resAtividades* (Linha 8) e o segmento (janela de tempo) é adaptado para receber os demais eventos relacionados a possível atividade reconhecida pelo algoritmo.

Figura 32 – Instância da arquitetura SeAct.



Fonte: Elaborado pela autora (2023).

Na Figura 32, uma instância da arquitetura apresentada na Figura 24 foi definida para detalhar com um exemplo o uso do método. O exemplo utiliza dois sensores, uma câmera e um sensor de pressão, com objetivo de capturar eventos sobre a postura humana, capturada pelo sensor de câmera e os objetos de uso, capturados pelo sensor de pressão implantado nos objetos. Três eventos,  $E_1, E_2, E_3$ , utilizam o copo como objeto de uso e diferentes posturas podem ser detectadas para esse objeto de uso, quando processados os eventos simples que são coletados por esses dois tipos de sensores. O exemplo possui posturas como, comendo, abrindo ou movimentando. Esses exemplos demonstram que o uso de eventos simples como, o uso de um objeto como o copo, pode representar diferentes atividades, contudo, quando esse evento é associado a outro evento como o de postura humana, é possível processar um evento complexo que auxilia na distinção das atividades. Inicialmente, para aprender as atividades dos usuários, é necessário aprender as posturas e objetos de uso utilizados individualmente. Ou seja, para cada usuário existe um comportamento diferente que precisa ser analisado e representado para a janela. Assim, foram definidos dois processos no método, um processo offline, que aprende posturas e objetos de uso para atividades e constrói regras semânticas. Um processo online que adquire eventos online, eventos simples, e processa esses eventos utilizando o raciocínio semântico nas regras previamente definidas. O modelo inferido, possui os atributos relacionados aos sensores, eventos e atividade, possibilitando a extração de atividades e suas durações. A duração será o novo intervalo de tempo, ou seja, o segmento com os eventos observados até o momento, que serão anotados utilizando o vocabulário (vide Seção 4). Aplicações, como a de RAH, utilizam esses segmentos para obter os demais eventos na janela definida e reconhecem atividades com maior precisão.

#### 5.4.2 Anotação

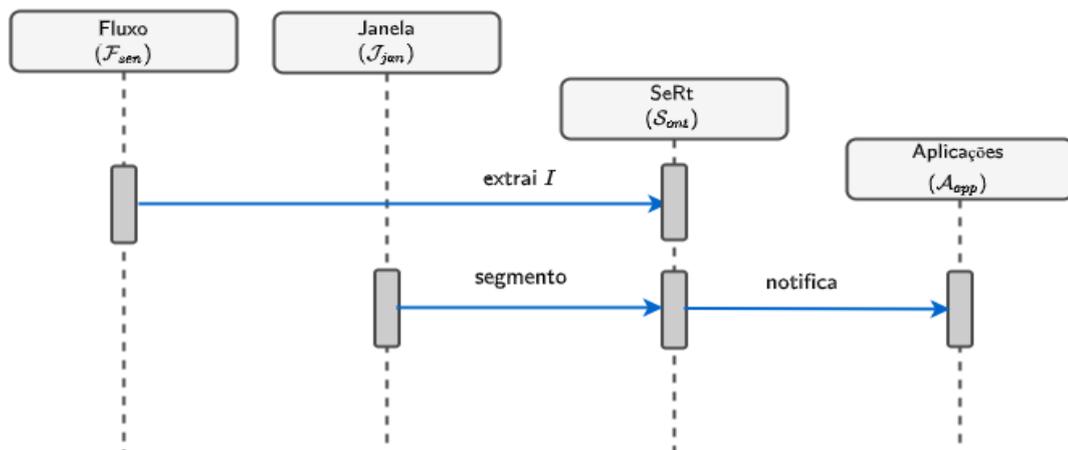
A tarefa de segmentação de dados realiza o processamento dos fluxos para que tarefas de análise possam ser executadas. Portanto, os resultados de segmentação devem apoiar a tarefa de análise provendo melhorias. No Capítulo 4, SeRt foi definida para anotar os segmentos e informações sobre os segmentos disponibilizando o conhecimento necessário para a tarefa de análise em AAL. Para exemplificar construímos o Protocolo 5 (Figura 33), que utiliza SeRt para anotar os segmentos produzidos por SeAct.

- **Objetivo:** anotar os segmentos gerados pela Operador de Janela, além das informações relacionadas aos mesmos.
- **Participantes:** Fluxo de Dados de Sensores  $\mathcal{F}_{sen}$ , Operador de Janela  $\mathcal{J}_{jan}$  que disponibiliza os segmentos gerados, SeRt  $\mathcal{S}_{ont}$  que anota o conhecimento disponível e Aplicações  $\mathcal{A}_{app}$  notificadas.

**Passos:**

1. Assumindo que  $\mathcal{S}_{ont}$  extrai informações sobre  $\mathcal{F}_{sen}$ .
2. Assumindo que  $\mathcal{J}_{jan}$  fornece segmentos.
3.  $\mathcal{S}_{ont}$  representa  $\mathcal{F}_{sen}$  e  $\mathcal{J}_{jan}$ , anotando os resultados em representação própria e disponibilizando para aplicações e serviços.

Figura 33 – Fluxo de trabalho da subetapa de anotação

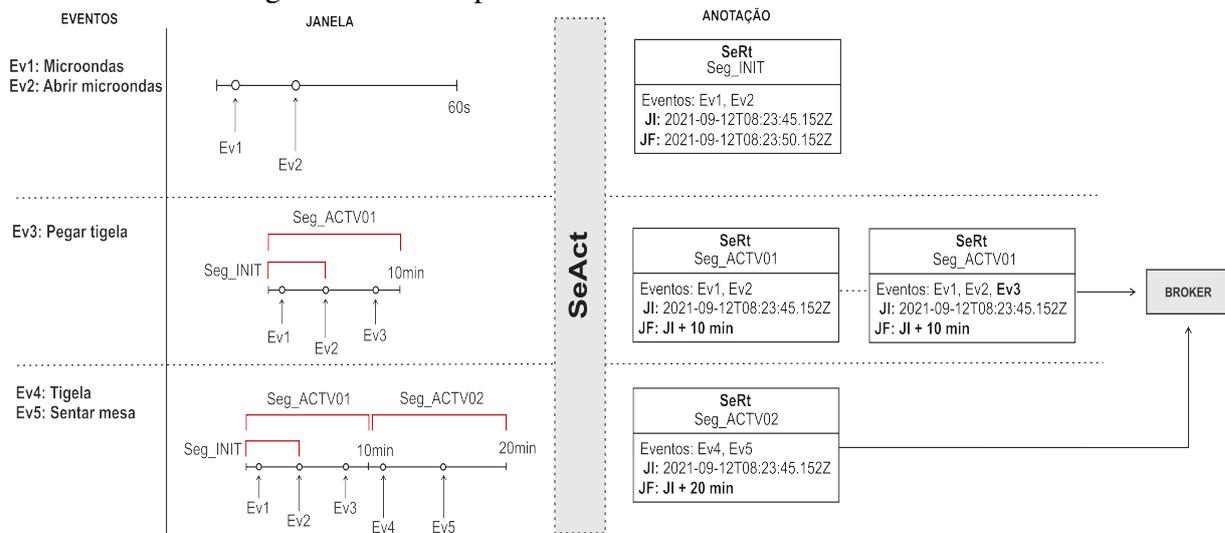


Fonte: Elaborado pela autora (2023).

Para exemplificar o processo de anotação um exemplo motivador é apresentado, simulando a aquisição de observações, como as observações são segmentadas utilizando SeAct e como a anotação de cada etapa ocorre.

Na Figura 34 um exemplo motivador é apresentado, exemplificando como o Operador de Janela é definido e como o resultado dos segmentos gerados necessita de representação para uso posterior pelas aplicações ou serviços. Inicialmente, duas observações são capturadas pelos sensores. Eventos simples, como o uso do micro-ondas e a postura de abrir o micro-ondas, são capturados em uma janela de 60 segundos e anotados. Nesse instante existe uma janela fixa, onde é possível os eventos para uso em SeAct. Com esses dois eventos simples, foi processado um evento complexo através de SeAct obtendo atividades como, preparar refeição e

Figura 34 – Exemplo motivador SeRt.



Fonte: Elaborado pela autora (2023).

sua respectiva duração. Assim, a janela inicial são adaptadas para uma janela de 10 minutos, onde posteriormente captura-se o evento de pegar tigela. Os eventos são então anotados e enviados para o *broker*. O *broker* faz parte de um sistema de publicação e assinatura, onde as informações são disponibilizadas para que os assinantes, que no contexto são os sistemas de reconhecimento de atividade, possam se inscrever e obter os segmentos gerados. Novos eventos são capturados como o uso da tigela e a postura de sentar na mesa, e uma nova atividade é inferida, como comendo, definindo uma nova janela de 20 minutos. Esse segmento é anotado e enviado para o *broker*. Mais detalhes sobre SeRt e seu processo de anotação podem ser encontrados no Capítulo 4.

## 5.5 Considerações Finais

Ao abordar técnicas híbridas para segmentação pode-se constatar que tratando-se do mundo real e de seus desafios, abordar a problemática de definir uma janela de tempo, ou segmento ideal para reconhecer uma atividade requer informações adicionais como destaca-se, sensores, eventos e usuários envolvidos nas ocorrências. No estudo de caso proposto para exemplificar as etapas *online* e *offline*, o módulo de processamento dos eventos complexos encontra-se no Operador de Janela, que também consome os eventos complexos para inferir uma atividade e obter sua duração. O contexto em que ocorrem as atividades, seja pelo uso dos objetos e a postura, ou posição dos corpos de seus usuários, e sua combinação, fornecem o suporte necessário para desambiguação de atividades e por consequência a definição do segmento adequado. Em SeAct, o processamento de eventos complexos se baseia nos padrões de

comportamento aprendidos pelo algoritmo de aprendizagem e na definição das regras aplicadas no Operador de Janela.

Outro fator importante está relacionado as plataformas ou serviços heterogêneos que disponibilizam eventos detectados por sensores, tornando-se assim um ambiente atrativo para as tecnologias semânticas, disponibilizam um vocabulário comum de representação.

Uma avaliação do método por meio de experimentos replicáveis que adotam conjuntos de dados conhecidos está disponível no Capítulo 6 dessa tese.

A seguir, um resumo das principais contribuições do capítulo:

- SeAct, um novo método híbrido que compreendem técnicas baseadas em dados e baseadas em conhecimento para segmentação de fluxos de dados de sensores.
  
- Solução de janela que utiliza o processamento de eventos complexos para desambiguação de atividades (i.e., quando um único sensor pode ser utilizado em mais de uma atividade, como, quando o copo pode ser utilizado por uma atividade de comer ou de limpeza desse objeto, propomos o uso de eventos complexos, como, o copo e a posição do humano, para melhoria na detecção da atividade). Esse aspecto possibilita a escolha por uma atividade e, conseqüentemente, escolha pelo segmento correspondente.

## 6 AVALIAÇÃO

Esse capítulo aborda a validação da ontologia SeRt e os experimentos utilizados para avaliar o método SeAct. O domínio escolhido para avaliar SeRt e SeAct é o de Reconhecimento de Atividade Humana (RAH). Na Seção 6.1, a validação do SeRt é apresentada, enquanto a Seção 6.2 discorre sobre os experimentos realizados no SeAct.

### 6.1 Validação da Ontologia SeRt

Nesta seção, a validação da ontologia SeRt por Questões de Competência (GRÜNINGER; FOX, 1995) é discutida. As Questões de Competência são questões de linguagem natural que especificam que conhecimento deve ser vinculado à ontologia e podem ser vistas como um conjunto de requisitos sobre o conteúdo (GRÜNINGER; FOX, 1995).

Uma ontologia deve ter axiomas suficientes para responder as Questões de Competência, delimitando o domínio do assunto que deve ser representado na ontologia. O objetivo é então validar a SeRt por questões relacionadas às técnicas de segmentação disponíveis na literatura.

A validação da SeRt foi realizada implementando a ontologia como RDF, apoiada pela ferramenta Protegé (PROTÉGÉ, 2008).

Na Tabela 8 são apresentadas as Questões de Competência baseadas nos requisitos da literatura no domínio de anotação de segmentos. Na Tabela 9 instâncias de SeRt foram criadas (como exemplos) utilizando consultas *SPARQL Protocol and RDF Query Language* (SPARQL) básicas para responder a cada Questão de Competência. Questões de Competência que tratam de metadados de sensores podem ser respondidas por algumas ontologias, como citadas na Seção 3.1, contudo, as Questões de Competência definidas na Tabela 8 se referem a questões sobre os metadados de segmentação, que incluem sensores, o segmento (i.e., janela) e os segmentos derivados, além de características e da análise utilizada.

A Tabela 8 representa Questões de Competência definidas a partir dos requisitos encontrados na literatura, particularmente, nas aplicações que utilizam os resultados da segmentação para tomada de decisão ou para reconhecimento de atividade.

Na Questão 1, a identificação dos sensores pode ser útil, por exemplo, quando os valores de segmento gerados podem ser diferentes para sensores que possuem diferentes precisões na captura. A Questão 2 anota os metadados gerados por esses sensores, ou seja, os

Tabela 8 – Questões de Competência para a ontologia SeRt

Identificador	Questão de Competência
(QC01)	Quais tipos de sensores derivam o segmento?
(QC02)	Quais são os resultados gerados pelos sensores que estão no segmento?
(QC03)	Que método de análise gerou o segmento?
(QC04)	Para quais características o método de análise gerou valores?
(QC05)	Quais são os métodos e características de atualização da análise?
(QC06)	Quais são os segmentos que derivam o segmento atual?
(QC07)	Quais são os rótulos do segmento?

Fonte: Elaborado pela autora (2023).

valores obtidos pela observação.

Os metadados anotados por SeRt podem ser utilizados para comparar técnicas ou para propor mudança em algum método, seja em uma etapa de aprendizagem de comportamento humano ou de análise baseada em conhecimento. Para tanto, as questões 3, 4 e 5 foram definidas. Por fim, para permitir a rastreabilidade dos segmentos, a Questão 6 foi descrita. A janela que iniciou o processo de segmentação pode ser útil para comparação dos resultados em diferentes métodos. Na Questão 7, os rótulos são anotados com os eventos que ocorreram dentro do segmento.

A Tabela 9 apresenta instâncias de SeRt utilizando consultas SPARQL para responder as Questões de Competência. Essa tabela apresenta na primeira coluna os identificadores para as Questões de Competência, na segunda coluna estão as consultas SPARQL e na terceira coluna os resultados para essas consultas que estão de acordo com o que o enunciado da pergunta define.

Na Questão 1, é necessário obter os sensores utilizados para definir o segmento, portanto, utilizando o vocabulário da ontologia SeRt e um filtro com horário e data de início e fim da captura do segmento, é possível obter os sensores de pressão e presença (i.e., *passive infrared* (PIR)). Para as questões 2, 3 e 4, o objetivo é obter os resultados para os eventos que ocorreram, por exemplo, tigela e movimento, e seus respectivos *timestamps*. Além disso, a ontologia utilizada e as características que fizeram parte da análise que permitiu a segmentação, como Atividade, Postura, e Objeto de Uso.

Na Questão 5 estão representados o método utilizado e as características utilizadas, por exemplo, o método de Agrupamento e os eventos de Postura e Objeto de uso. A Questão 6 refere-se ao segmento gerado apresentando os seus *timestamps* inicial e final, e, por fim, na Questão 7, os eventos Tigela e Movimento são resultados do segmento. Sistemas de RAH podem utilizar os eventos ocorridos até o momento em que o segmento foi definido para o reconhecimento de atividade.

Tabela 9 – Exemplo de consultas para Questões de Competência em SeRt

Identificador	Questão de Competência	Resultado
(QC01)	SELECT ?type WHERE { ?sensor a sosa:Sensor. ?sensor sosa:madeBySensor ?sensor. ?sensor a sert:ObservacoSensor. ?sensor sert:pertenceA ?seg. ?seg a sert:Segmento. ?seg sert:janelaInicio ?ws. ?seg sert:janelaFim ?we. FILTER((?ws >= "2011-11-28T10:25:44Z") and (?we <= "2011-11-28T10:33:00Z"))}	Pressão PIR
(QC02)	SELECT ?dataSensor WHERE { ?dataSensor a sert:ObservacoSensor. ?dataSensor sert:pertenceA ?seg. ?seg a sert:Segmento. ?seg sert:janelaInicio ?ws. ?seg sert:janelaFim ?we. FILTER((?ws >= "2011-11-28T10:25:44Z") and (?we <= "2011-11-28T10:33:00Z"))}	Tigela 2011-11-28T10:25:44 Movimento 2011-11-28T10:29:44
(QC03)	SELECT DISTINCT ?instance WHERE { ?analise a sert:Analise; ?analise sert:metodo ?instancia. ?analise sert:geradoPor ?seg. ?seg a sert:Segmento. ?seg sert:janelaInicio ?ws. ?seg sert:janelaFim ?we. FILTER((?ws >= "2011-11-28T10:25:44Z") and (?we <= "2011-11-28T10:33:00Z"))}	URI da ontologia
(QC04)	SELECT DISTINCT ?instancia WHERE { ?analise a sert:Analise; ?analise sert:caracteristicas ?instancia. ?analise sert:geradoPor ?seg. ?seg a sert:Segmento. ?seg sert:janelaInicio ?ws. ?seg sert:janelaFim ?we. FILTER((?ws >= "2011-11-28T10:25:44Z") and (?we <= "2011-11-28T10:33:00Z"))}	Atividade, Postura, Objeto de Uso
(QC05)	SELECT DISTINCT ?metodo ?caracteristicas WHERE { ?analise a sert:Analise; ?analise sert:metodo ?metodo. ?analise sert:caracteristica ?caracteristica. ?analise sert:atualizadoPor ?seg. ?seg a sert:Segmento. ?seg sert:janelaInicio ?ws. ?seg sert:janelaFim ?we. FILTER((?ws >= "2011-11-28T10:25:44Z") and (?we <= "2011-11-28T10:33:00Z"))}	Agrupamento Postura, Objeto de uso
(QC06)	SELECT DISTINCT ?instancia WHERE { ?instance a sert:Segmento; ?instancia sert:derivadoDe ?seg. ?seg a sert:Segmento. ?seg sert:janelaInicio ?ws. ?seg sert:janelaFim ?we. FILTER((?ws >= "2011-11-28T10:25:44Z") and (?we <= "2011-11-28T10:33:00Z"))}	2011-11-28T10:25:44 2011-11-28T10:26:44
(QC07)	SELECT DISTINCT ?rotulo WHERE { ?seg a sert:Segmento; ?seg sert:eventos ?eventos. ?seg sert:janelaInicio ?ws. ?seg sert:janelaFim ?we. FILTER((?ws >= "2011-11-28T10:25:44Z") and (?we <= "2011-11-28T10:33:00Z"))}	Tigela, Movimento

Fonte: Elaborado pela autora (2023).

## 6.2 Experimentos com o Método SeAct

Esta seção apresenta a avaliação realizada por meio de um experimento para avaliar o método SeAct proposto no Capítulo 5. O domínio de aplicação escolhido é o AAL, ou casas inteligentes, particularmente, para RAH. O monitoramento de ambientes como casas inteligentes constroem a base de conhecimento necessária para aplicações de RAH adotadas por cuidadores, médicos e hospitais, que avaliam os residentes em sua rotina.

Através desse monitoramento, os sistemas de RAH conseguem detectar anomalias acionando alarmes e provendo dados necessários para o acompanhamento clínico dos residentes. Para uma comparação justa, foram adotados conjuntos de dados conhecidos, o CAD-120 (KOPPULA *et al.*, 2013) e o Kasteren (KASTEREN *et al.*, 2008).

Para os três experimentos executados, a metodologia de avaliação e experimentação proposta por (WOHLIN *et al.*, 2012) foi seguida.

Segundo (WOHLIN *et al.*, 2012), o processo do experimento pode ser dividido nas seguintes atividades: (i) Definição, em que o experimento é definido em termos de problema e objetivo que deve ser alcançado; (ii) Planejamento, no qual o experimento deve ser projetado; (iii) Operação, que é a execução do experimento e avaliação da hipótese; (iv) Análise e Interpretação, que se refere à análise e discussão dos resultados; e (v) Replicabilidade, que trata da apresentação dos resultados do experimento.

As próximas subseções apresentam os experimentos realizados seguindo as atividades sugeridas por (WOHLIN *et al.*, 2012), conforme mencionado anteriormente. A Subseção 6.2.1 mostra o primeiro experimento utilizando o conjunto de dados CAD-120. A Subseção 6.2.2 apresenta o segundo e terceiro experimentos utilizando o conjunto de dados Kasteren, comparando os resultados do uso de janela estática e dinâmica. Finalmente, a Subseção 6.2.3 discute as ameaças à validade do experimento.

### 6.2.1 Conjunto de Dados CAD-120

O primeiro experimento utilizando o conjunto de dados CAD-120 é definido a seguir.

- **Definição.** O objetivo deste experimento é analisar os resultados de inferência de atividades do método SeAct, para uma escolha de segmento adequado. Assim, a finalidade é verificar o quão frequente a saída do método está correta (i.e, a acurácia do SeAct) e,

daquelas atividades que o método inferiu como corretas, quantas efetivamente estavam certas (i.e., a precisão do SeAct). A detecção de atividade ocorre no contexto de eventos obtidos por ações realizadas em uma casa inteligente. Portanto, para o experimento foram definidas as questões Q1 e Q2 da seguinte forma:

- **Q1** - A acurácia é aumentada quando o SeAct é seguido? Justificativa: Esta questão pretende avaliar se o método de segmentação proposto detecta atividades com maior acurácia do que o trabalho de Díaz-Rodríguez *et al.* (2014) baseado no uso do mesmo conjunto de dados.
- **Q2** - A precisão é aumentada quando o SeAct é seguido? Justificativa: Esta questão pretende avaliar se o método de segmentação proposto detecta atividades com maior precisão do que o trabalho de Díaz-Rodríguez *et al.* (2014) baseado no uso do mesmo conjunto de dados.

Então, para responder às perguntas definidas, duas métricas foram definidas nas Equações (6.1) e (6.2) (SAMMUT; WEBB, 2011), onde  $vp$  significa verdadeiros positivos,  $vn$  para verdadeiros negativos,  $fp$  para falsos positivos e  $fn$  para falsos negativos, como segue:

$$precisao = vp / (vp + fp) \quad (6.1)$$

$$acuracia = (vp + vn) / (vp + vn + fp + fn) \quad (6.2)$$

- **Planejamento.** Foram definidas as hipóteses a serem investigadas, as variáveis, foi realizado o delineamento do experimento e foram definidos os recursos utilizados. O planejamento do experimento realizado para avaliar os resultados gerados pelo SeAct é detalhado nas subseções a seguir.
  - Hipótese relacionada a **Q1**, onde AcuráciaComSeAct se refere ao uso da equação 6.2 para medir os resultados do método SeAct e AcuráciaComDiaz se refere ao uso da equação 6.2 para medir os resultados sem uso de heurísticas apresentados em

Díaz-Rodríguez *et al.* (2014).

-  $HA_0$  : AcuráciaComSeAct = AcuráciaComDiaz

-  $HA_1$  : AcuráciaComSeAct > AcuráciaComDiaz

- Hipótese relacionada a **Q2**, onde PrecisãoComSeAct se refere ao uso da equação 6.2 para medir os resultados do método SeAct e PrecisãoComDiaz se refere ao uso da equação 6.2 para medir os resultados sem uso de heurísticas apresentados em Díaz-Rodríguez *et al.* (2014).

-  $HP_0$  : PrecisãoComSeAct = PrecisãoComDiaz

-  $HP_1$  : PrecisãoComSeAct > PrecisãoComDiaz

Para as questões Q1 e Q2, a hipótese nula ( $HA_0$  e  $HP_0$ ) afirma que o uso do método SeAct fornece os mesmos resultados de Díaz-Rodríguez *et al.* (2014), enquanto a hipótese alternativa afirma que o método SeAct têm resultados aumentados em relação a acurácia ( $HA_1$ ) e precisão ( $HP_1$ ). Neste experimento, a variável independente é o conjunto de dados utilizado, o CAD-120. As variáveis dependentes são as métricas de acurácia e precisão que foram definidas para responder às questões do experimento.

- **Operação.** Antes da execução do experimento, todos os recursos apresentados no Capítulo 5 foram preparados. Para realizar esse experimento, o conjunto de dados CAD-120 foi utilizado. Esse conjunto de dados consiste em sequências de vídeo RGB-D de humanos realizando 12 ADLs diferentes (compostas por várias subatividades) gravadas com o Sensor Microsoft Kinect. Um total de 4 residentes participaram do experimento, dois homens e duas mulheres (um deles é canhoto).

Como ambiente de desenvolvimento foi utilizada a ferramenta Eclipse e o código escrito em Java. Experimentos foram executados em máquina com iOS 11.5.2 com um Intel Core i5 Dual-Core (1,8 GHz, 1600 MHz DDR3) e 8 GB de RAM.

A avaliação foi realizada considerando a abordagem de Díaz-Rodríguez *et al.* (2014), que usa o mesmo conjunto de dados de reconhecimento de atividades e técnica híbrida. O trabalho de Díaz-Rodríguez *et al.* (2014) utiliza uma etapa de aprendizagem de máquina, na qual, particularmente, faz uso do algoritmo k-NN. Utilizando o resultado ou atividades classificadas como entrada para um módulo de raciocínio baseado em conhecimento.

Para uma comparação justa, a saída do módulo de aprendizagem que menciona cinco atividades passíveis de uso para o reconhecimento foi utilizada, incluindo seu armazenamento, que utiliza uma estrutura de dados chamada tabela de dispersão. O código disponível<sup>1</sup> apresenta as etapas utilizadas pelos autores. Os resultados sem uso de heurísticas são comparados com os resultados de SeAct.

- **Análise e Interpretação.** O conjunto de dados CAD-120 não fornece informações que ajudem na distinção dos usuários envolvidos no experimento. Nessa perspectiva não é possível discutir os resultados para características dos usuários (e.g., o usuário canhoto, ou por gênero).

Nossos resultados são comparados aos resultados encontrados no trabalho de Díaz-Rodríguez *et al.* (2014). O método híbrido de Díaz-Rodríguez *et al.* (2014) armazena os resultados da aprendizagem de máquina em uma tabela de distribuição em uma abordagem que não usa semântica temporal para associar eventos simples e conseqüentemente inferir atividades.

Eventos simples podem estar relacionados a diferentes atividades, ocasionando a diminuição de acurácia e precisão na detecção de atividades e conseqüentemente uma escolha errônea pelo segmento corresponde.

A Tabela 10 a seguir apresenta os resultados da comparação das abordagens SeAct e Díaz-Rodríguez *et al.* (2014).

Conforme os resultados apresentados na Tabela 10, as hipóteses nulas  $HA_0$  e  $HP_0$  podem

<sup>1</sup> <https://github.com/NataliaDiaz/HumanActivityRecognitionFuzzyDescriptionLogics>

Tabela 10 – Comparação da abordagem para o reconhecimento de atividades usando o conjunto de dados CAD-120.

Método	Precisão	Acurácia
Díaz-Rodríguez et al.	64.1	61.36
SeAct	70.3	68.0

Fonte: Elaborado pela autora (2023).

ser rejeitadas, visto que, o método SeAct supera a abordagem de Díaz-Rodríguez *et al.* (2014) em termos de acurácia e precisão, alcançando uma precisão de 70,3 e acurácia de 68,0 superiores respectivamente aos 64,1 e 61,36 de Díaz-Rodríguez *et al.* (2014). Sendo assim, as hipóteses alternativas ( $HA_1$  e  $HP_1$ ) podem ser aceitas.

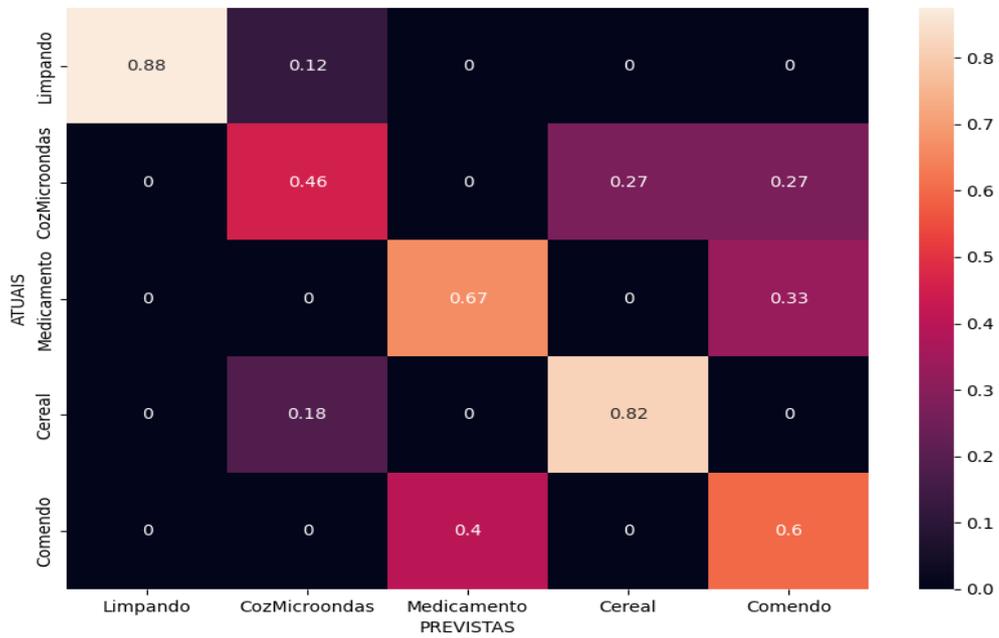
Duas matrizes de confusão (STEHMAN, 1997) são apresentadas para apresentar comparar os resultados para cada atividade. A matriz de confusão exibe a distribuição dos registros em termos de suas classes atuais e de suas classes previstas em valores definidos por número de falsos positivos, falsos negativos, verdadeiros positivos e verdadeiros negativos, permitindo uma análise mais detalhada.

Para representar os resultados do método SeAct a matriz de confusão (Figura 35) é apresentada a seguir.

A Figura 35 apresenta uma matriz de confusão construída utilizando os resultados de SeAct. Na vertical da matriz encontram-se as atividades atuais e na horizontal as atividades previstas. As atividades Limpando, CozMicroondas, Medicamento, Cereal e Comendo apresentam resultados precisos em toda distribuição apresentada.

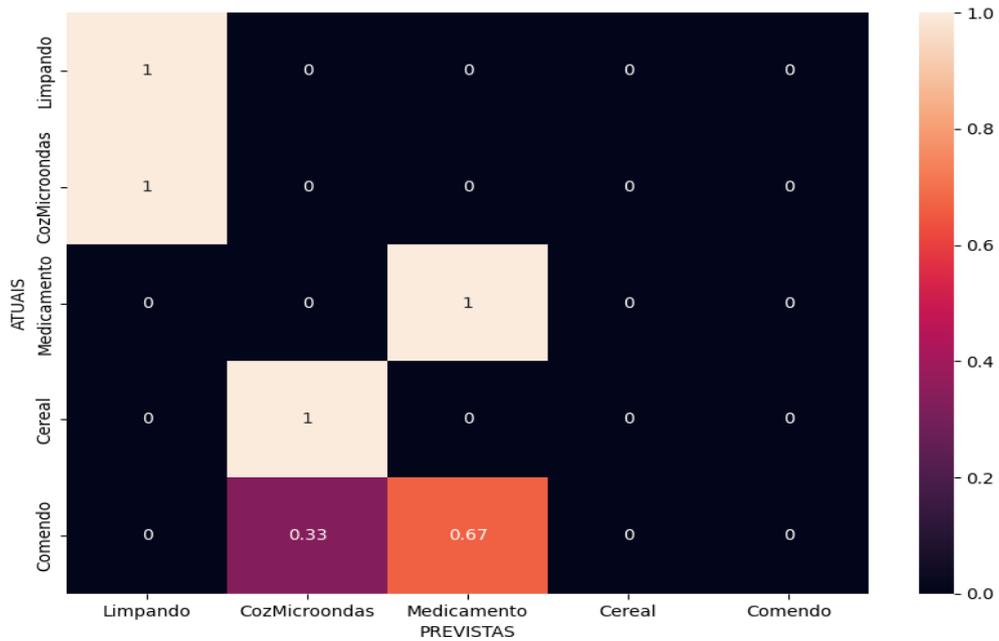
A Figura 36 apresenta uma matriz de confusão construída utilizando os resultados de Díaz-Rodríguez *et al.* (2014). Os resultados para as atividades atuais e previstas são apresentados em um mapa de calor que representa o percentual de acertos de atividades. É possível observar que em atividades como Limpando e Medicamento, o método de Díaz-Rodríguez *et al.* (2014) acerta em 100% dos casos. Para a atividade CozMicroondas não existe acerto, todos os resultados encontrados são para a atividade Limpando. Na atividade Cereal não existe acerto, todos os resultados encontrados são para a atividade CozMicroondas e por fim, para a atividade Comendo não existe acerto, em 0.67% dos casos a atividade prevista foi Medicamento e em 0.33% a atividade prevista foi CozMicroondas.

Figura 35 – Matriz de confusão SeAct para atividades no conjunto de dados CAD-120.



Fonte: Elaborado pela autora (2023).

Figura 36 – Matriz de confusão de Díaz-Rodríguez *et al.* (2014) para atividades no conjunto de dados CAD-120.



Fonte: Elaborado pela autora (2023).

Analisando os resultados é possível entender que atividades como Limpando (objetos) e CozMicroondas, podem inferir atividades incorretamente. Objetos de uso em comum, como o uso do micro-ondas para cozinhar e também para limpeza podem impactar na classificação da classe correta (i.e., a atividade). O mesmo acontece para as atividades Cereal, CozMicroondas e Comendo, que utilizam objetos em comum (e.g., uma tigela) e o uso desse objeto para inferir corretamente uma atividade pode ser insuficiente.

- **Replicabilidade.** Para garantir a replicabilidade dos experimentos, o código do método SeAct encontra-se disponível <sup>2</sup>.

## 6.2.2 Conjunto de Dados Kasteren

Dois trabalhos encontrados na literatura adotam o conjunto de dados Kasteren. O primeiro estudo avalia os resultados obtidos pelo uso de janela estática e o segundo estudo avalia os resultados obtidos pelo uso de janela dinâmica. Nas seções a seguir, a metodologia e os resultados utilizados são detalhados.

### 6.2.2.1 Resultados da segmentação adotando janela estática

O segundo experimento utiliza o conjunto de dados Kasteren e compara resultados encontrados em uma abordagem Kasteren *et al.* (2008) que utiliza uma janela estática de 60 segundos e SeAct.

- **Definição.** O objetivo deste experimento é analisar os resultados de inferência de atividades do método SeAct, para uma escolha de segmento adequado. Assim, a finalidade é verificar o quão frequente a saída do método está correta (i.e, a acurácia do SeAct). A detecção de atividade ocorre no contexto de eventos obtidos por ações realizadas em uma casa inteligente. Portanto, para o experimento foi definida a Questão Q1 da seguinte forma:
  - **Q1** - A acurácia é aumentada quando o SeAct é seguido? Justificativa: Esta questão pretende avaliar se o método de segmentação proposto detecta atividades com maior acurácia do que o trabalho de Kasteren *et al.* (2008) baseado no uso do mesmo conjunto de dados.

<sup>2</sup> <https://github.com/amandadrielly/SeAct>

Então, para responder às perguntas definidas, uma métrica foi definida na Equação (6.1) (SAMMUT; WEBB, 2011), onde  $vp$  significa verdadeiros positivos,  $vn$  para verdadeiros negativos,  $fp$  para falsos positivos e  $fn$  para falsos negativos, como segue:

$$acuracia = (vp + vn) / (vp + vn + fp + fn) \quad (6.3)$$

- **Planejamento.** Foram definidas as hipóteses a serem investigadas, variáveis, bem como o delineamento do experimento e os recursos utilizados. O planejamento do experimento realizado para avaliar os resultados gerados pelo SeAct é detalhado nas subseções a seguir.
  - Hipótese relacionada a **Q1**, onde AcuráciaComSeAct se refere ao uso da equação 6.1 para medir os resultados do método SeAct e AcuráciaComKasteren se refere ao uso da equação 6.1 para medir os resultados apresentados em Kasteren *et al.* (2008).
    - $HA_0$  : AcuráciaComSeAct = AcuráciaComKasteren
    - $HA_1$  : AcuráciaComSeAct > AcuráciaComKasteren

Para a Questão Q1, a hipótese nula ( $HA_0$ ) afirma que o uso do método SeAct fornece os mesmos resultados de Kasteren *et al.* (2008), enquanto a hipótese alternativa afirma que o método SeAct têm resultados aumentados em relação a acurácia ( $HA_1$ ) das atividades detectadas. Neste experimento, a variável independente é o conjunto de dados utilizado Kasteren. A variável dependente é a métrica de acurácia que foi definida para responder a questão do experimento.

- **Operação.** Para realizar esse experimento, o conjunto de dados Kasteren foi utilizado. O conjunto de dados consiste em dados coletados durante 28 dias, que monitoraram as AVD realizadas por um único habitante, um homem de 26 anos que morava sozinho em um apartamento de três cômodos. Este conjunto de dados contém 245 atividades que são anotadas no fluxo de sensores, gerados por 14 sensores. Cada sensor está localizado em: micro-ondas, porta do banheiro, porta do banheiro, armário, geladeira, armário de pratos, porta da frente, lava-louças, descarga do vaso sanitário, freezer, armário de painéis,

máquina de lavar, armário de mercearia e porta do quarto. Sete atividades diferentes foram anotadas pelo residente, sendo elas: ir para a cama, usar o banheiro, preparar o café da manhã, preparar o jantar, tomar uma bebida, tomar banho e sair de casa. A Tabela 11 apresenta o número de eventos do sensor por atividade.

Tabela 11 – Eventos do sensor por atividade no conjunto de dados Kasteren.

Atividade	Eventos do Sensor	Eventos do Sensor (média)	Eventos do Sensor (dp)
Pegar bebida	69	3,45	1,00
Ir para cama	74	3,08	1,06
Sair de casa	113	3,32	2,06
Preparar café da manhã	100	5,00	1,30
Preparar jantar	64	6,40	1,58
Tomar banho	53	2,30	0,56
Usar o banheiro	376	3,30	0,81
	1.319		

Fonte: Adaptado de (SALGUERO *et al.*, 2018)

Na Tabela 11, a quantidade de eventos do sensor coletados, sua média e desvio padrão (dp) são descritos para cada atividade no conjunto de dados Kasteren. A medida de acurácia foi escolhida após observação do conjunto de dados Kasteren (vide Tabela 11) em termos de quantidade de eventos, média e desvio padrão.

Como ambiente de desenvolvimento foi utilizada a ferramenta Eclipse e o código escrito em Java. Experimentos foram executados em máquina com iOS 11.5.2 com um Intel Core i5 Dual-Core (1,8 GHz, 1600 MHz DDR3) e 8 GB de RAM. As métricas foram coletadas e analisadas.

A avaliação é realizada considerando a abordagem de Kasteren *et al.* (2008) que adota o mesmo conjunto de dados para RAH e janela estática de 60 segundos de duração. A abordagem adota dois modelos, o Modelo Oculto de Markov, um modelo probabilístico que consiste em uma variável oculta e uma variável observável, sendo a variável oculta a atividade realizada e a variável observável o vetor de leituras do sensor. Além disso, um modelo de Campo Aleatório Condicional e um modelo probabilístico discriminativo foram avaliados em uma série de experimentos.

É necessário destacar que valores nulos no conjunto foram excluídos e que o conjunto de

dados anotado proposto em Kasteren *et al.* (2008) adiciona ao mesmo evento o objeto de uso e sua localização, como, por exemplo, um evento, porta de entrada. Essa anotação não reflete um cenário real, onde os eventos são capturados por diferentes sensores e anotados como eventos simples. Para tanto, SeAct define esses eventos separadamente, com objetivo de refletir um cenário de reconhecimento *online* de atividades.

- **Análise e Interpretação.** A abordagem de Kasteren *et al.* (2008) é baseada em dados e utiliza uma janela estática de 60 segundos. Esse experimento é importante para destacar que o conjunto de dados permite uma melhoria da acurácia quando seus eventos simples são associados, participando de um processamento de eventos complexos. Além disso, SeAct define o segmento utilizando a primeira atividade detectada, o que poderia impactar na acurácia pela possibilidade de maiores associações entre eventos, objetos de uso e localização, que estão relacionados a diferentes atividades. Com base nos resultados apresentados na Tabela 12, a hipótese nula  $HA_0$  pode ser rejeitada e sua hipótese alternativa ( $HA_1$ ) pode ser aceita. O método SeAct supera a abordagem de Kasteren *et al.* (2008) em termos de acurácia, alcançando uma precisão de 86,71 superando os 73,30 de Kasteren *et al.* (2008).

#### 6.2.2.2 Resultados da segmentação adotando janela dinâmica

O terceiro experimento utiliza o conjunto de dados Kasteren e compara resultados encontrados em uma abordagem Salguero *et al.* (2018) que utiliza uma janela dinâmica e SeAct.

- **Definição.** O objetivo deste experimento é analisar os resultados de inferência de atividades do método SeAct, para uma escolha de segmento adequado. Assim, a finalidade é verificar o quão frequente a saída do método está correta (i.e, a acurácia do SeAct). A detecção de atividade ocorre no contexto de eventos obtidos por ações realizadas em uma casa inteligente. Portanto, para o experimento foi definida a Questão Q1 da seguinte forma:
  - **Q1** A acurácia é aumentada quando o SeAct é seguido? Justificativa: Esta questão pretende avaliar se o método de segmentação proposto detecta atividades com maior acurácia do que o trabalho de Salguero *et al.* (2018) baseado no uso do mesmo conjunto de dados.

Então, para responder às perguntas definidas, uma métrica foi definida na Equação (6.1) (SAMMUT; WEBB, 2011), onde  $vp$  significa verdadeiros positivos,  $vn$  para verdadeiros negativos,  $fp$  para falsos positivos e  $fn$  para falsos negativos, como segue:

$$acuracia = (vp + vn) / (vp + vn + fp + fn) \quad (6.4)$$

- **Planejamento.** Foram definidas as hipóteses a serem investigadas, variáveis, bem como o delineamento do experimento e os recursos utilizados. O planejamento do experimento realizado para avaliar os resultados gerados pelo SeAct é detalhado nas subseções a seguir.
  - Hipótese relacionada a **Q1**, onde AcuráciaComSeAct se refere ao uso da equação 6.1 para medir os resultados do método SeAct e AcuráciaComSalguero se refere ao uso da equação 6.1 para medir os resultados apresentados em Salguero *et al.* (2018).
    - $HA_0$  : AcuráciaComSeAct = AcuráciaComSalguero
    - $HA_1$  : AcuráciaComSeAct > AcuráciaComSalguero

Para a Questão Q1, a hipótese nula ( $HA_0$ ) afirma que o uso do método SeAct fornece os mesmos resultados de Salguero *et al.* (2018), enquanto a hipótese alternativa afirma que o método SeAct têm resultados aumentados em relação a acurácia ( $HA_1$ ) das atividades detectadas. Neste experimento, a variável independente é o conjunto de dados utilizado Kasteren. A variável dependente é a métrica de acurácia que foi definida para responder a questão do experimento.

- **Operação.** Para realizar esse experimento, o conjunto de dados Kasteren foi utilizado. Como ambiente de desenvolvimento foi utilizada a ferramenta Eclipse e o código escrito em Java. Experimentos foram executados em máquina com iOS 11.5.2 com um Intel Core i5 Dual-Core (1,8 GHz, 1600 MHz DDR3) e 8 GB de RAM. As métricas foram coletadas e analisadas.

A avaliação é realizada considerando a abordagem de Salguero *et al.* (2018) que adota o

mesmo conjunto de dados e uma estratégia de segmentação de janela dinâmica. O objetivo do experimento de Salguero *et al.* (2018) é determinar se a atividade alvo foi ou não realizada. Para tanto, a proposta define uma ontologia e utiliza LD para inferir relacionamentos entre os eventos adquiridos. A saída dessa etapa será a entrada para um classificador. No experimento, os autores avaliam alguns classificadores, como C4.5, Otimização Sequencial Mínima, Perceptron Votado, Florestas Aleatórias e Tabela de Decisão.

- **Análise e Interpretação.** A abordagem de Salguero *et al.* (2018) adota o mesmo conjunto de dados e uma estratégia de segmentação híbrida para uma janela dinâmica. O trabalho de Salguero *et al.* (2018) identifica os eventos pelos seus relacionamentos baseados em senso comum, ou seja, eventos e atividades são previamente modelados utilizando um padrão de comportamento comum para que quando identificados, novos relacionamentos sejam inferidos. Características obtidas por esses relacionamentos são utilizadas para inferir atividades através dos diferentes classificadores testados.

Portanto, o trabalho de Salguero *et al.* (2018) não utiliza o comportamento do residente, mas, conhecimento de senso comum e não associa eventos simples, o que pode impactar na acurácia.

A Tab. 12 apresenta os resultados da comparação entre as abordagens de Kasteren *et al.* (2008), Salguero *et al.* (2018) e SeAct.

Tabela 12 – Comparação de abordagens que utilizam o Kasteren.

Método	Acurácia
(KASTEREN <i>et al.</i> , 2008)	73.30
(SALGUERO <i>et al.</i> , 2018)	85.25
SeAct	86.71

Fonte: Elaborado pela autora (2023).

Conforme a Tab. 12, enquanto o trabalho de Salguero *et al.* (2018) relatou 85,25%. SeAct apresenta 86.71 de acurácia superando as abordagens de Kasteren *et al.* (2008) e Salguero *et al.* (2018). Com base nos resultados apresentados na Tabela 12, a hipótese nula  $HA_0$  pode ser rejeitada e sua hipótese alternativa ( $HA_1$ ) pode ser aceita.

- **Replicabilidade.** Para garantir a replicabilidade dos experimentos, o código do método

SeAct encontra-se disponível <sup>3</sup>.

### 6.2.3 Ameaças à Validade

Os experimentos apresentados contêm as ameaças à validade (CAMPBELL; STANLEY, 2015) discutidas a seguir.

Mesmo com uma metodologia de experimentação que define uma hipótese em que os eventos simples podem ser combinados para desambiguar atividades, não é possível garantir que todo evento simples seja satisfatório ou suficiente. As razões para isso são as seguintes: (i) o número de amostras em um conjunto de dados pode impactar o desempenho e os resultados; e (ii) o conjunto de dados precisa apresentar eventos, atividades e intervalos de tempo.

Para mitigar essas ameaças, um estudo de revisão sistemática foi elaborado para identificar os trabalhos relevantes, seus conjuntos de dados e métodos propostos. Por fim, o método de Díaz-Rodríguez *et al.* (2014) visa reconhecer atividades, sendo a segmentação parte do processo. Assim, foram executados experimentos até a etapa de segmentação para obter uma comparação justa. Para o conjunto de dados Kasteren e os trabalhos de Kasteren *et al.* (2008) e Salguero *et al.* (2018), a falta de reprodutibilidade não permitiu que os trabalhos fossem testados com a separação entre os eventos detectados por objetos de uso e localização, refletindo um cenário de reconhecimento *online* de atividades.

---

<sup>3</sup> <https://github.com/amandadrielly/SeAct>

## 7 CONCLUSÃO

Para concluir esta tese, este capítulo trata das considerações finais e está organizado da seguinte maneira. Na Seção 7.1, as Questões de Pesquisa definidas no Capítulo 1 são revisitadas e discutidas. Na Seção 7.2, as contribuições do trabalho são apresentadas, enquanto a Seção 7.3 se destina às publicações decorrentes da tese e as periféricas. Por fim, os trabalhos futuros são discutidos na Seção 7.4.

### 7.1 Um breve resumo

O interesse crescente por monitoramento e cuidados domésticos relacionados à saúde e assistência impulsiona a difusão de sensores e plataformas que disponibilizam aplicações e serviços cada vez mais úteis para a rotina humana. Diversas plataformas monitoram e disponibilizam dados fornecidos pelos sensores implantados em AAL e a comunidade tem investigado os problemas e desafios desse tópico de pesquisa. Os componentes de um AAL fornecem a estrutura necessária para integração de diferentes tecnologias que apoiam esses serviços e aplicações. O Ambiente de Vida Assistida segue um ciclo de vida que consiste geralmente na aquisição, processamento e análise dos dados antes da tomada de decisões.

Essa tese enfatizou então uma problemática da fase de processamento, pois ainda existe espaço para melhorias no que diz respeito à precisão e desambiguação dos resultados, especialmente pela escassez de soluções de segmentação de fluxos de dados de sensores que processam eventos complexos para essa finalidade. Sendo assim, este trabalho propôs um método híbrido de segmentação de fluxos de dados de sensores que utiliza processamento de eventos complexos e inferência semântica com enfoque na desambiguação dos dados para escolha do segmento que corresponde a atividade em curso.

### 7.2 Revisitando as Questões de Pesquisa

Na Seção 1.3 foram apresentadas questões de pesquisa que guiaram o desenvolvimento desta tese. Assim, tendo como base os resultados apresentados nos Capítulos 4 e 5 e nas respectivas avaliações descritas no Capítulo 6, é possível definir respostas para essas questões, as quais são apresentadas a seguir:

- **QP1.** Quais técnicas de segmentação de dados podem ser adequadas para reconhecer e

interpretar fluxos de dados de sensores?

Com base nos trabalhos elencados pelo Estudo de Mapeamento Sistemático (vide Seção 2.2) foi possível reunir conceitos bem como estruturar e definir técnicas de segmentação de fluxos de dados de sensores disponíveis na literatura. Investigando as limitações entre as técnicas e as abordagens propostas por estudos que implementavam estas técnicas, foi possível definir que o método necessitava de uma técnica híbrida que suportasse a aprendizagem de novos comportamentos que também seriam úteis para definir mecanismos baseados em conhecimento, obtendo comportamentos individuais. O resultado do mapeamento apoiou então a escolha pelas técnicas baseadas em dados e conhecimento, conhecidas como técnicas híbridas, para definição e desenvolvimento do método SeAct proposto nesta tese.

- **QP2.** Quais abordagens podem ser adotadas para segmentar fluxos de dados de sensores garantindo desambiguação?

Após investigação sobre as técnicas segmentação de fluxos de dados (vide Seção 2.2), particularmente, técnicas híbridas, e, alinhando a hipótese 1 e o objetivo dessa tese, foi desenvolvido o método SeAct (Capítulo 5). O método híbrido SeAct dispõe de etapas *offline* e *online* com o propósito de obter o comportamento de residentes para compor regras semânticas que através de eventos complexos podem inferir atividades diferentes pela associação de eventos. Assim, o método fornece meios para desambiguação de atividades. Para efeitos de comparação com alguns trabalhos da literatura, na Seção 6.2, três experimentos foram realizados para definir melhorias de precisão e acurácia utilizando diferentes conjuntos de dados públicos. Os resultados dessas comparações são promissores e podem ser encontrados na Seção 6.2.

- **QP3.** Quais ontologias podem ser adotadas para representar metadados relacionados a segmentação dinâmica de fluxos de dados?

Informações entre as etapas do ciclo AAL, particularmente, entre o processamento e análise, necessitam de representação. Dentre as informações necessárias existem recursos

heterogêneos como metadados de sensores e técnicas aplicadas na segmentação. Tecnologias semânticas podem ser empregadas para fins de expressividade, consulta e rastreamento. Para tanto, para responder quais ontologias podem ser adotadas, foram levantadas ontologias da literatura (Seção 3.2) e suas limitações. Algumas ontologias descrevem o sensor e/ou conjunto de fluxos de dados. Contudo, os segmentos gerados por eventos obtidos por análises não são representados. Além disso, a segmentação dinâmica requer anotação de metadados dos segmentos, criando uma referência para as janelas geradas. Portanto, para representar os metadados da segmentação dinâmica de fluxos de dados, e, alinhando a hipótese 2 e o objetivo dessa tese, a ontologia SeRt (Capítulo 4) foi desenvolvida. Para avaliar a SeRt, Questões de Competência foram definidas e podem ser encontradas na Seção 6.1.

### 7.3 Contribuições e Limitações do Trabalho

Nesta tese destaca-se as seguintes contribuições principais:

- SeAct: Método Híbrido de Segmentação de Fluxo de Dados de Sensores. A fim de processar de forma online um fluxo de dados de sensores, foi proposto um método híbrido que segmenta dinamicamente os fluxos de dados adaptando o tamanho da janela, conforme a possível atividade em curso. Para atingir esse objetivo, uma abordagem híbrida adota técnicas baseadas em dados e técnicas baseadas em conhecimento. O princípio geral da abordagem é a seguinte: dada uma coleta de dados anotada pelo usuário refletindo atividades da vida diária e um conjunto de recursos do aplicativo, os eventos são associados por meio do processamento de eventos complexos. Para tanto, os resultados obtidos através de um algoritmo de aprendizagem são semanticamente representados usando uma ontologia definida e regras de inferência são construídas para relacionar eventos às atividades. Durante o processo *online*, a ontologia e as regras de são consultadas pelo algoritmo de segmentação para recuperar o conhecimento. Assim, o tamanho ideal do segmento de dados atual deve ser escolhido; e
- SeRt: Ontologia para anotação de segmentos oriundos da segmentação dinâmica de fluxos de dados de sensores. A principal novidade da ontologia SeRt é que ela permite o rastreamento e consulta dos segmentos e dos recursos que derivam os segmentos. A validação

proposta por Questões de Competência confirma a viabilidade da ontologia SeRt e sua capacidade de anotação e rastreamento, úteis para qualquer consumidor que deseja adotar as saídas de segmentação para tarefa de análise de sua aplicação ou serviço.

Como contribuição secundária, um mapeamento sistemático foi realizada sobre os esforços de pesquisa na área de AAL, segmentação de fluxos de dados de sensores e ontologias para anotação semântica de fluxos de dados de sensores com foco no RAH. Nessa revisão foi possível concluir que os esforços são recentes e que é uma área promissora que possui bastante potencial de exploração. Esta tese também considerou técnicas baseadas em dados, baseadas em conhecimento e híbridas para segmentação de dados, destacando suas respectivas limitações e desvantagens. Como resultado do mapeamento, foi destacada a problemática de desambiguação de atividades, além de um vocabulário para descrever o processo de segmentação, que resultou no método híbrido proposto. Superar esses desafios é essencial para permitir processamento e análise eficientes para aplicativos em AAL.

Assim como as contribuições propostas apresentam diversas vantagens e comprovaram sua viabilidade por meio de diversos experimentos e validações, elas também apresentam limitações. Em primeiro lugar, a problemática dessa tese se baseia no processamento de eventos complexos para desambiguação dos conceitos, o que foi explorado utilizando uma técnica baseada em conhecimento para segmentação online de fluxos de dados de sensores. Em segundo lugar, a disponibilidade de conjunto de dados anotado é limitada. Existe uma variedade de abordagens e conjuntos de dados anotando os objetos de uso, nos quais inexistem relação com outros eventos. Em terceiro lugar, os usuários nem sempre aceitam monitorar suas vidas, mesmo por um período curto. Por fim, nem sempre há especialistas disponíveis para os procedimentos técnico-científicos necessários.

#### **7.4 Publicações**

Nesta seção são detalhados os principais trabalhos publicados e as submissões realizadas durante o doutoramento. A primeira parte diz respeito aos trabalhos que têm relação direta com as contribuições presentes na tese e a segunda parte já elenca os trabalhos desenvolvidos de forma correlata com o tema da tese.

Na Tabela 13, estão dispostas as publicações já ocorridas a partir da tese e foram importantes para o seu desenvolvimento e melhorias.

O trabalho (VENCESLAU *et al.*, 2021) foi apresentado no fórum de trabalhos de doutorado em andamento. Neste artigo, uma versão inicial da proposta desta tese foi apresentada, particularmente, tratando das técnicas híbridas. No evento, foi possível compartilhar experiências com outros estudantes e obter considerações da comunidade de sistemas ubíquos. No trabalho (VENCESLAU *et al.*, 2022), foi apresentado o método SeAct e foram recebidas considerações sobre o método e experimentos. Por fim, no trabalho (VENCESLAU *et al.*, 2019) foi apresentada uma revisão sistemática sobre interoperabilidade semântica no contexto de IoT, no qual foi possível estudar ontologias no domínio de IoT e fluxos de dados de sensores. Esse estudo foi importante para elaboração da ontologia SeRt.

Tabela 13 – Publicações decorrentes da tese.

Tipo do Trabalho	Evento	Referência	Novo Qualis
Conferência	PerCom	(VENCESLAU <i>et al.</i> , 2021)	A2
Conferência	SBBD	(VENCESLAU <i>et al.</i> , 2022)	A4
Conferência	ICEIS	(VENCESLAU <i>et al.</i> , 2019)	B2

Fonte: Elaborado pela autora (2023).

Na Tabela 14, constam as publicações periféricas realizadas durante o período do doutorado em que a candidata é co-autora e o tema se relaciona diretamente com os aspectos subjacentes aos estudos realizados no desenvolvimento da tese.

Tabela 14 – Publicações decorrentes da tese.

Tipo do Trabalho	Evento	Referência	Novo Qualis
Periódico	Artificial Intelligence Review	(SILVA <i>et al.</i> , 2020)	A2
Periódico	JIDM	(AVILA <i>et al.</i> , 2021)	B2
Conferência	SBIE	(AVILA <i>et al.</i> , 2018)	B1
Conferência	ICEIS	(Costa Junior. <i>et al.</i> , 2022)	B2
Conferência	ICEIS	(ARRUDA <i>et al.</i> , 2020)	B2
Conferência	ICEIS	(AVILA <i>et al.</i> , 2019)	B2

Fonte: Elaborado pela autora (2023).

Os trabalhos descritos na Tabela 14 são subjacentes, mas importantes para o desenvolvimento desta tese e para o fortalecimento da colaboração entre pesquisadores, a qual ocorreu durante o período de doutorado. O trabalho (SILVA *et al.*, 2020) é uma revisão sobre *question answering* onde foi possível estudar algoritmos de aprendizagem de máquina, também aplicada nesta tese na etapa *offline* do método SeAct. No trabalho (AVILA *et al.*, 2021) foi desenvolvido um *Chatbot* baseado em ontologia para recuperar informações sobre medicamentos e comparar seus preços. Esse trabalho anteriormente publicado em uma conferência (AVILA *et al.*, 2019), foi publicado em uma revista. O desenvolvimento de ontologias e uso de ferramentas são aspectos

utilizados nesta tese para o desenvolvimento de SeRt. O mesmo ocorre com os trabalhos (AVILA *et al.*, 2018; ARRUDA *et al.*, 2020) que propõem o uso de semântica, particularmente, mashup de dados. Por fim, o trabalho (Costa Junior. *et al.*, 2022) é uma revisão na literatura cinza sobre dados em Internet of Health Things (IoHT), onde foi possível concluir que os conjuntos de dados públicos em RAH são escassos, reforçando a limitação que elencamos nos experimentos apresentamos nesta tese.

## 7.5 Trabalhos Futuros

Esta tese conduziu um conjunto de contribuições que abrem múltiplas perspectivas para pesquisas futuras. Nesta seção são definidas as perspectivas de trabalhos futuros que foram identificadas.

- É importante comparar os resultados aqui apresentados com outros métodos que utilizam o mesmo conjunto de dados;
- Falhas na detecção eventos e atividades podem impactar na construção das regras de inferência. É necessário considerar que a adição de novos conceitos na ontologia ActiOn (e.g., o turno do dia em que ocorrem determinadas atividades) pode aumentar o poder de inferência das regras.
- Outras ontologias para descrição de localização dos sensores podem ser utilizadas (e.g., ontologias voltadas para ambientes *indoor*).
- Outras problemáticas também podem ser investigadas como o uso da segmentação em sistemas auto adaptativos que consideram os padrões de movimento e a postura humana.
- Outra perspectiva promissora é RAH multiusuário, avaliando o método em detrimento de outros métodos que utilizam o RAH de único usuário. Isso significa que quanto mais de uma pessoa está na casa inteligente, os recursos semânticos e a complexidade dos padrões de comportamento podem ser fundamentais para o raciocínio e tomada de decisão. Este ainda é um problema desafiador, apesar dos avanços encontrados no tópico de RAH; e

- Também é possível citar o reconhecimento sequencial de atividade, ou reconhecimento de atividades paralelas, como um potencial trabalho futuro. Atividades como se alimentar enquanto assiste TV denotam duas atividades ocorrendo em paralelo, por exemplo.

Até onde foi possível pesquisar nesta tese, esses problemas merecem destaque e são tópicos atuais de pesquisas realizadas pela maioria das aplicações em Ambiente de Vida Assistida.

## REFERÊNCIAS

- AAL. **Active and Assisted Living Programme. Aalp objectives**. 2021. Disponível em: <http://www.aal-europe.eu/>. Acesso em: 07-Maio-2021.
- ACM. **ACM Digital Library**. 2021. Disponível em: <https://dl.acm.org/>. Acesso em: 07-Abril-2021.
- AKBAR, A.; CHAUDHRY, S. S.; KHAN, A.; ALI, A.; RAFIQ, W. On complex event processing for internet of things. In: IEEE. **2019 IEEE 6th International Conference on Engineering Technologies and Applied Sciences (ICETAS)**. [S. l.], 2019. p. 1–7.
- AKBAR, A.; KHAN, A.; CARREZ, F.; MOESSNER, K. Predictive analytics for complex iot data streams. **IEEE Internet of Things Journal**, IEEE, v. 4, n. 5, p. 1571–1582, 2017.
- ALGHAMDI, S.; FADEL, E.; ALOWIDI, N. Recognizing activities of daily living using 1d convolutional neural networks for efficient smart homes.
- ARP, R.; SMITH, B.; SPEAR, A. D. **Building ontologies with basic formal ontology**. [S. l.]: Mit Press, 2015.
- ARRUDA, N.; VENCESLAU, A.; CRUZ, M. M. Lima da; VIDAL, V. M.; PEQUENO, V. M. Publishing and consuming semantic views for construction of knowledge graphs. In: SCITEPRESS DIGITAL LIBRARY. **22nd International Conference on Enterprise Information Systems (ICEIS)**. [S. l.], 2020. p. 197–204.
- ASGHARI, P.; SOLEIMANI, E.; NAZERFARD, E. Online human activity recognition employing hierarchical hidden markov models. **Journal of Ambient Intelligence and Humanized Computing**, Springer, v. 11, n. 3, p. 1141–1152, 2020.
- AVILA, C.; CALIXTO, A.; ROLIM, T.; FRANCO, W.; VENCESLAU, A.; VIDAL, V.; PEQUENO, V.; MOURA, F. Medibot: an ontology based chatbot for portuguese speakers drug's users. In: SCITEPRESS. **International Conference on Enterprise Information Systems**. [S. l.], 2019. v. 1, p. 25–36.
- AVILA, C. V.; ROLIM, T. V.; CRUZ, M. M. L. da; PIRES, A.; FRANCO, J. W.; VIDAL, V. Um linked data mashup de dados de execuções financeiras e indicadores educacionais no ensino básico. In: **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**. [S. l.: s. n.], 2018. v. 29, n. 1, p. 1911.
- AVILA, C. V. S.; FRANCO, W.; VENCESLAU, A. D.; ROLIM, T. V.; VIDAL, V. M.; PEQUENO, V. M. Medibot: An ontology-based chatbot to retrieve drug information and compare its prices. **Journal of Information and Data Management**, v. 12, n. 2, 2021.
- BAO, L.; INTILLE, S. S. Activity recognition from user-annotated acceleration data. In: SPRINGER. **International conference on pervasive computing**. [S. l.], 2004. p. 1–17.
- BERMUDEZ-EDO, M.; ELSALEH, T.; BARNAGHI, P.; TAYLOR, K. Iot-lite: a lightweight semantic model for the internet of things. In: IEEE. **2016 INTL IEEE conferences on ubiquitous intelligence & computing, advanced and trusted computing, scalable computing and communications, cloud and big data computing, internet of people, and smart world congress (uic/atc/scalcom/cbdcom/iop/smartworld)**. [S. l.], 2016. p. 90–97.

BONTE, P.; TOMMASINI, R.; VALLE, E. D.; TURCK, F. D.; ONGENAE, F. Streaming massif: cascading reasoning for efficient processing of iot data streams. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 18, n. 11, p. 3832, 2018.

CAMPBELL, D. T.; STANLEY, J. C. **Experimental and quasi-experimental designs for research**. [S. l.]: Ravenio books, 2015.

CASAS. **Center of Advanced Studies In Adaptive System**. 2021. Disponível em: <http://ailab.wsu.edu/casas/datasets/>. Acesso em: 07-Maio-2021.

CHEN, C. Y.; FU, J. H.; SUNG, T.; WANG, P.-F.; JOU, E.; FENG, M.-W. Complex event processing for the internet of things and its applications. In: IEEE. **2014 IEEE International Conference on Automation Science and Engineering (CASE)**. [S. l.], 2014. p. 1144–1149.

CHEN, L.; BABAR, M. A.; ZHANG, H. Towards an evidence-based understanding of electronic data sources. In: **14th International Conference on Evaluation and Assessment in Software Engineering (EASE)**. [S. l.: s. n.], 2010. p. 1–4.

CHEN, L.; NUGENT, C.; OKEYO, G. An ontology-based hybrid approach to activity modeling for smart homes. **IEEE Transactions on human-machine systems**, IEEE, v. 44, n. 1, p. 92–105, 2013.

CIVITARESE, G.; BETTINI, C.; SZTYLER, T.; RIBONI, D.; STUCKENSCHMIDT, H. Nectar: Knowledge-based collaborative active learning for activity recognition. In: IEEE. **2018 IEEE International Conference on Pervasive Computing and Communications (PerCom)**. [S. l.], 2018. p. 1–10.

CIVITARESE, G.; PRESOTTO, R.; BETTINI, C. Context-driven active and incremental activity recognition. **arXiv preprint arXiv:1906.03033**, 2019.

CIVITARESE, G.; SZTYLER, T.; RIBONI, D.; BETTINI, C.; STUCKENSCHMIDT, H. Polaris: Probabilistic and ontological activity recognition in smart-homes. **IEEE Transactions on Knowledge and Data Engineering**, IEEE, v. 33, n. 1, p. 209–223, 2019.

COCAPS. **CoCAPS**. 2021. Disponível em: <https://www.s2e2.fr/en/projets/cocaps-en/>. Acesso em: 07-Maio-2021.

COMPTON, M.; BARNAGHI, P.; BERMUDEZ, L.; GARCIA-CASTRO, R.; CORCHO, O.; COX, S.; GRAYBEAL, J.; HAUSWIRTH, M.; HENSON, C.; HERZOG, A. *et al.* The ssn ontology of the w3c semantic sensor network incubator group. **Journal of Web Semantics**, Elsevier, v. 17, p. 25–32, 2012.

COOK, D. J. Learning setting-generalized activity models for smart spaces. **IEEE intelligent systems**, NIH Public Access, v. 2010, n. 99, p. 1, 2010.

COOK, D. J.; CRANDALL, A. S.; THOMAS, B. L.; KRISHNAN, N. C. Casas: A smart home in a box. **Computer**, IEEE, v. 46, n. 7, p. 62–69, 2012.

Costa Junior., E.; ANDRADE., R.; VENCESLAU., A.; OLIVEIRA., P.; SANTOS., I.; OLIVEIRA., B. Where is the internet of health things data? In: INSTICC. **Proceedings of the 24th International Conference on Enterprise Information Systems - Volume 1: ICEIS**, [S. l.]: SciTePress, 2022. p. 39–49. ISBN 978-989-758-569-2. ISSN 2184-4992.

CUGOLA, G.; MARGARA, A.; MATTEUCCI, M.; TAMBURRELLI, G. Introducing uncertainty in complex event processing: model, implementation, and validation. **Computing**, Springer, v. 97, n. 2, p. 103–144, 2015.

DÍAZ-RODRÍGUEZ, N.; CADAHÍA, O. L.; CUÉLLAR, M. P.; LILIUS, J.; CALVO-FLORES, M. D. Handling real-world context awareness, uncertainty and vagueness in real-time human activity tracking and recognition with a fuzzy ontology-based hybrid method. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 14, n. 10, p. 18131–18171, 2014.

DONG, Y.; LIU, J.; GAO, Y.; SARKAR, S.; HU, Z.; FAGERT, J.; PAN, S.; ZHANG, P.; NOH, H. Y.; MIRSHEKARI, M. A window-based sequence-to-one approach with dynamic voting for nurse care activity recognition using acceleration-based wearable sensor. In: **Adjunct Proceedings of the 2020 ACM International Joint Conference on Pervasive and Ubiquitous Computing and Proceedings of the 2020 ACM International Symposium on Wearable Computers**. [S. l.: s. n.], 2020. p. 390–395.

DUARTE, P. A.; BARRETO, F. M.; AGUILAR, P. A.; BOUDY, J.; ANDRADE, R. M.; VIANA, W. Aal platforms challenges in iot era: a tertiary study. In: IEEE. **2018 13th Annual Conference on System of Systems Engineering (SoSE)**. [S. l.], 2018. p. 106–113.

ECONOMIC, D. of; AFFAIRS POPULATION DIVISION, U. N. S. World population prospects 2019: highlights (st/esa/ser. a/423). 2019.

EDDY, S. R. Hidden markov models. **Current opinion in structural biology**, Elsevier, v. 6, n. 3, p. 361–365, 1996.

ELSALEH, T.; ENSHAEIFAR, S.; REZVANI, R.; ACTON, S. T.; JANEIKO, V.; BERMUDEZ-EDO, M. Iot-stream: A lightweight ontology for internet of things data streams and its use with data analytics and event detection services. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 20, n. 4, p. 953, 2020.

FACT++. **Fact++**. 2020. Disponível em: <http://owl.man.ac.uk/factplusplus/>. Acesso em: 07-Dezembro-2020.

FU, T.-c. A review on time series data mining. **Engineering Applications of Artificial Intelligence**, Elsevier, v. 24, n. 1, p. 164–181, 2011.

FÜLÖP, L. J.; BESZÉDES, Á.; TÓTH, G.; DEMETER, H.; VIDÁCS, L.; FARKAS, L. Predictive complex event processing: a conceptual framework for combining complex event processing and predictive analytics. In: **Proceedings of the Fifth Balkan Conference in Informatics**. [S. l.: s. n.], 2012. p. 26–31.

GANGEMI, A.; GUARINO, N.; MASOLO, C.; OLTRAMARI, A.; SCHNEIDER, L. Sweetening ontologies with dolce. In: SPRINGER. **International Conference on Knowledge Engineering and Knowledge Management**. [S. l.], 2002. p. 166–181.

GARIJO, D. Prov-o: The prov ontology tutorial. In: **Proc. Int. Conf. Dublin Core Metadata Appl.** [S. l.: s. n.], 2013. p. 48–50.

GAYATHRI, K.; EASWARAKUMAR, K.; ELIAS, S. Probabilistic ontology based activity recognition in smart homes using markov logic network. **Knowledge-Based Systems**, Elsevier, v. 121, p. 173–184, 2017.

GRÜNINGER, M.; FOX, M. S. Methodology for the design and evaluation of ontologies. Citeseer, 1995.

GUBER, T. A translational approach to portable ontologies. **Knowledge Acquisition**, v. 5, n. 2, p. 199–229, 1993.

GUIZZARDI, G. Ontological foundations for structural conceptual models. 2005.

HALLER, A.; JANOWICZ, K.; COX, S. J.; LEFRANÇOIS, M.; TAYLOR, K.; PHUOC, D. L.; LIEBERMAN, J.; GARCÍA-CASTRO, R.; ATKINSON, R.; STADLER, C. The modular ssn ontology: A joint w3c and ogc standard specifying the semantics of sensors, observations, sampling, and actuation. **Semantic Web**, IOS Press, v. 10, n. 1, p. 9–32, 2019.

HEFLIN, J. *et al.* An introduction to the owl web ontology language. **Lehigh University. National Science Foundation (NSF)**, p. 7, 2007.

HELAOUI, R.; RIBONI, D.; STUCKENSCHMIDT, H. A probabilistic ontological framework for the recognition of multilevel human activities. In: **Proceedings of the 2013 ACM international joint conference on Pervasive and ubiquitous computing**. [S. l.: s. n.], 2013. p. 345–354.

HERMIT. **HermiT OWL Reasoner**. 2020. Disponível em: <http://www.hermit-reasoner.com/>. Acesso em: 07-Dezembro-2020.

HERRE, H. General formal ontology (gfo): A foundational ontology for conceptual modelling. In: **Theory and applications of ontology: computer applications**. [S. l.]: Springer, 2010. p. 297–345.

HORROCKS, I.; PATEL-SCHNEIDER, P. F.; BOLEY, H.; TABET, S.; GROSOFF, B.; DEAN, M. *et al.* Swrl: A semantic web rule language combining owl and ruleml. **W3C Member submission**, v. 21, n. 79, p. 1–31, 2004.

HUSSAIN, Z.; SHENG, M.; ZHANG, W. E. Different approaches for human activity recognition: A survey. **arXiv preprint arXiv:1906.05074**, 2019.

JARRAYA, A.; RAMOLY, N.; BOUZEGHOUB, A.; AROUR, K.; BORGI, A.; FINANCE, B. A fuzzy semantic cep model for situation identification in smart homes. In: **Proceedings of the Twenty-second European Conference on Artificial Intelligence**. [S. l.: s. n.], 2016. p. 1678–1679.

JENA. **Reasoners and rule engines: Jena inference support**. 2020. Disponível em: <https://jena.apache.org/documentation/inference/>. Acesso em: 07-Dezembro-2020.

JUNIOR, B. R.; ANDRADE, R. M.; MAIA, M. E.; NOGUEIRA, T. P. Succeed: Support mechanism for creating and executing workflows for decoupled sas in iot. In: **IEEE. 2018 IEEE 42nd Annual Computer Software and Applications Conference (COMPSAC)**. [S. l.], 2018. v. 2, p. 738–743.

KASTEREN, T. V.; NOULAS, A.; ENGLEBIENNE, G.; KRÖSE, B. Accurate activity recognition in a home setting. In: **Proceedings of the 10th international conference on Ubiquitous computing**. [S. l.: s. n.], 2008. p. 1–9.

KEOGH, E.; CHAKRABARTI, K.; PAZZANI, M.; MEHROTRA, S. Dimensionality reduction for fast similarity search in large time series databases. **Knowledge and information Systems**, Springer, v. 3, n. 3, p. 263–286, 2001.

KEPLER, F. N.; PAZ-TRILLO, C.; RIANI, J.; RIBEIRO, M. M.; DELGADO, K. V.; BARROS, L. N. de; WASSERMANN, R. Classifying ontologies. In: **WONTO**. [S. l.: s. n.], 2006.

KITCHENHAM, B.; CHARTERS, S. Guidelines for performing systematic literature reviews in software engineering. Citeseer, 2007.

KITCHENHAM, B. A.; BUDGEN, D.; BRERETON, O. P. The value of mapping studies—a participant-observer case study. In: **14th international conference on evaluation and assessment in software engineering (ease)**. [S. l.: s. n.], 2010. p. 1–9.

KNIJFF, J. D.; FRASINCAR, F.; HOGENBOOM, F. Domain taxonomy learning from text: The subsumption method versus hierarchical clustering. **Data & Knowledge Engineering**, Elsevier, v. 83, p. 54–69, 2013.

KOLOZALI, S.; BERMUDEZ-EDO, M.; PUSCHMANN, D.; GANZ, F.; BARNAGHI, P. A knowledge-based approach for real-time iot data stream annotation and processing. In: **IEEE. 2014 IEEE International Conference on Internet of Things (iThings), and IEEE Green Computing and Communications (GreenCom) and IEEE Cyber, Physical and Social Computing (CPSCom)**. [S. l.], 2014. p. 215–222.

KOPPULA, H. S.; GUPTA, R.; SAXENA, A. Learning human activities and object affordances from rgb-d videos. **The International Journal of Robotics Research**, SAGE Publications Sage UK: London, England, v. 32, n. 8, p. 951–970, 2013.

KRISHNAN, N. C.; COOK, D. J. Activity recognition on streaming sensor data. **Pervasive and mobile computing**, Elsevier, v. 10, p. 138–154, 2014.

KRÖTZSCH, M.; SIMANCIK, F.; HORROCKS, I. A description logic primer. **arXiv preprint arXiv:1201.4089**, 2012.

LAGUNA, J. O.; OLAYA, A. G.; BORRAJO, D. A dynamic sliding window approach for activity recognition. In: **SPRINGER. International conference on user modeling, adaptation, and personalization**. [S. l.], 2011. p. 219–230.

LAI, K.; BO, L.; REN, X.; FOX, D. A large-scale hierarchical multi-view rgb-d object dataset. In: **IEEE. 2011 IEEE international conference on robotics and automation**. [S. l.], 2011. p. 1817–1824.

LE-PHUOC, D.; QUOC, H. N. M.; QUOC, H. N.; NHAT, T. T.; HAUSWIRTH, M. The graph of things: A step towards the live knowledge graph of connected things. **Journal of Web Semantics**, Elsevier, v. 37, p. 25–35, 2016.

LIU, L.; WANG, S.; SU, G.; HUANG, Z.-G.; LIU, M. Towards complex activity recognition using a bayesian network-based probabilistic generative framework. **Pattern Recognition**, Elsevier, v. 68, p. 295–309, 2017.

MAIA, M. E.; FONTELES, A.; NETO, B.; GADELHA, R.; VIANA, W.; ANDRADE, R. M. Locom-loosely coupled context acquisition middleware. In: **Proceedings of the 28th Annual ACM Symposium on Applied Computing**. [S. l.: s. n.], 2013. p. 534–541.

MALLICK, M.; KODESWARAN, P.; SEN, S.; KOKKU, R.; GANGULY, N. Tsfs: An integrated approach for event segmentation and adl detection in iot enabled smarthomes. **IEEE Transactions on Mobile Computing**, IEEE, v. 18, n. 11, p. 2686–2700, 2018.

MEHDIYEV, N.; KRUMEICH, J.; WERTH, D.; LOOS, P. Determination of event patterns for complex event processing using fuzzy unordered rule induction algorithm with multi-objective evolutionary feature subset selection. In: IEEE. **2016 49th Hawaii International Conference on System Sciences (HICSS)**. [S. l.], 2016. p. 1719–1728.

MEMON, M.; WAGNER, S. R.; PEDERSEN, C. F.; BEEVI, F. H. A.; HANSEN, F. O. Ambient assisted living healthcare frameworks, platforms, standards, and quality attributes. **Sensors**, MDPI, v. 14, n. 3, p. 4312–4341, 2014.

NGUYEN, T. A.; AIELLO, M. Energy intelligent buildings based on user activity: A survey. **Energy and buildings**, Elsevier, v. 56, p. 244–257, 2013.

NILES, I.; PEASE, A. Towards a standard upper ontology. In: **Proceedings of the international conference on Formal Ontology in Information Systems-Volume 2001**. [S. l.: s. n.], 2001. p. 2–9.

NOOR, M. H. M.; SALCIC, Z.; KEVIN, I.; WANG, K. Adaptive sliding window segmentation for physical activity recognition using a single tri-axial accelerometer. **Pervasive and Mobile Computing**, Elsevier, v. 38, p. 41–59, 2017.

NOY, N. F.; MCGUINNESS, D. L. *et al.* **Ontology development 101: A guide to creating your first ontology**. [S. l.]: Stanford knowledge systems laboratory technical report KSL-01-05 and . . . , 2001.

OBERLE, D. **Semantic management of middleware**. [S. l.]: Springer Science & Business Media, 2006. v. 1.

OKEYO, G.; CHEN, L.; WANG, H.; STERRITT, R. Dynamic sensor data segmentation for real-time knowledge-driven activity recognition. **Pervasive and Mobile Computing**, Elsevier, v. 10, p. 155–172, 2014.

PAI, M.; MCCULLOCH, M.; GORMAN, J. D.; PAI, N.; ENANORIA, W.; KENNEDY, G.; THARYAN, P.; JR, J. M. C. Systematic reviews and meta-analyses: an illustrated, step-by-step guide. **The National medical journal of India**, v. 17, n. 2, p. 86–95, 2004.

PAN, S.; BERGES, M.; RODAKOWSKI, J.; ZHANG, P.; NOH, H. Y. Fine-grained recognition of activities of daily living through structural vibration and electrical sensing. In: **Proceedings of the 6th ACM International Conference on Systems for Energy-Efficient Buildings, Cities, and Transportation**. [S. l.: s. n.], 2019. p. 149–158.

PATEL, A.; SHAH, J. Smart ecosystem to facilitate the elderly in ambient assisted living. In: SPRINGER. **Proceedings of International Conference on Recent Trends in Machine Learning, IoT, Smart Cities and Applications**. [S. l.], 2021. p. 501–510.

PETERSEN, E.; TO, M. A.; MAAG, S. An online learning based approach for cep rule generation. In: IEEE. **2016 8th IEEE Latin-American Conference on Communications (LATINCOM)**. [S. l.], 2016. p. 1–6.

- POLI, R.; HEALY, M.; KAMEAS, A. **Theory and applications of ontology: Computer applications**. [S. l.]: Springer, 2010.
- PRESTES, E.; CARBONERA, J. L.; FIORINI, S. R.; JORGE, V. A.; ABEL, M.; MADHAVAN, R.; LOCORO, A.; GONCALVES, P.; BARRETO, M. E.; HABIB, M. *et al.* Towards a core ontology for robotics and automation. **Robotics and Autonomous Systems**, Elsevier, v. 61, n. 11, p. 1193–1204, 2013.
- PROTÉGÉ, P. Disponível em <http://protege.stanford.edu>. Acesso em 24/04/2021, v. 17, 2008.
- RAIMOND, Y. **A distributed music information system**. Tese (Doutorado), 2008.
- RAWASHDEH, M.; ZAMIL, M. G. A.; SAMARAH, S.; HOSSAIN, M. S.; MUHAMMAD, G. A knowledge-driven approach for activity recognition in smart homes based on activity profiling. **Future Generation Computer Systems**, Elsevier, v. 107, p. 924–941, 2020.
- RIBONI, D.; BETTINI, C. Cosar: hybrid reasoning for context-aware activity recognition. **Personal and Ubiquitous Computing**, Springer, v. 15, n. 3, p. 271–289, 2011.
- RIBONI, D.; BETTINI, C.; CIVITARESE, G.; JANJUA, Z. H.; HELAOUI, R. Smartfaber: Recognizing fine-grained abnormal behaviors for early detection of mild cognitive impairment. **Artificial intelligence in medicine**, Elsevier, v. 67, p. 57–74, 2016.
- RUY, F. B.; FALBO, R. d. A.; BARCELLOS, M. P.; COSTA, S. D.; GUIZZARDI, G. Seon: A software engineering ontology network. In: SPRINGER. **European Knowledge Acquisition Workshop**. [S. l.], 2016. p. 527–542.
- SALGUERO, A. G.; ESPINILLA, M.; DELATORRE, P.; MEDINA, J. Using ontologies for the online recognition of activities of daily living. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 18, n. 4, p. 1202, 2018.
- SAMMUT, C.; WEBB, G. I. **Encyclopedia of machine learning**. [S. l.]: Springer Science & Business Media, 2011.
- SCHERP, A.; SAATHOFF, C.; FRANZ, T.; STAAB, S. Designing core ontologies. **Applied Ontology**, IOS Press, v. 6, n. 3, p. 177–221, 2011.
- SCIENCEDIRECT. **IEEE Xplore Digital Library**. 2021. Disponível em: <https://www.sciencedirect.com>. Acesso em: 07-Abril-2021.
- SECURE. **SECURE: Intelligent System for Early Diagnosis and Follow-up at Home**. 2021. Disponível em: <http://secure.evlab.di.unimi.it/>. Acesso em: 07-Maio-2021.
- SERPUSH, F.; MENHAJ, M. B.; MASOUMI, B.; KARASFI, B. Wearable sensor-based human activity recognition in the smart healthcare system. **Computational Intelligence and Neuroscience**, Hindawi, v. 2022, 2022.
- SFAR, H. **Real time intelligent decision making from heterogeneous and imperfect data**. Tese (Doutorado), 2019.
- SFAR, H.; BOUZEGHOUB, A. Dataseg: dynamic streaming sensor data segmentation for activity recognition. In: **Proceedings of the 34th ACM/SIGAPP Symposium on Applied Computing**. [S. l.: s. n.], 2019. p. 557–563.

- SILVA, J. W. F. da; VENCESLAU, A. D. P.; SALES, J. E.; MAIA, J. G. R.; PINHEIRO, V. C. M.; VIDAL, V. M. P. A short survey on end-to-end simple question answering systems. **Artificial Intelligence Review**, Springer, v. 53, n. 7, p. 5429–5453, 2020.
- SIRIN, E.; PARSIA, B. Sparql-dl: Sparql query for owl-dl. In: CITESEER. **OWLED**. [S. l.], 2007. v. 258.
- STEHMAN, S. V. Selecting and interpreting measures of thematic classification accuracy. **Remote sensing of Environment**, Elsevier, v. 62, n. 1, p. 77–89, 1997.
- SUJITH, A.; SAJJA, G. S.; MAHALAKSHMI, V.; NUHMANI, S.; PRASANALAKSHMI, B. Systematic review of smart health monitoring using deep learning and artificial intelligence. **Neuroscience Informatics**, Elsevier, v. 2, n. 3, p. 100028, 2022.
- TRIBOAN, D.; CHEN, L.; CHEN, F.; WANG, Z. Semantic segmentation of real-time sensor data stream for complex activity recognition. **Personal and Ubiquitous Computing**, Springer, v. 21, n. 3, p. 411–425, 2017.
- TRIBOAN, D.; CHEN, L.; CHEN, F.; WANG, Z. A semantics-based approach to sensor data segmentation in real-time activity recognition. **Future Generation Computer Systems**, Elsevier, v. 93, p. 224–236, 2019.
- VENCESLAU, A.; ANDRADE, R.; VIDAL, V.; NOGUEIRA, T.; PEQUENO, V. Iot semantic interoperability: a systematic mapping study. In: SCITEPRESS. **International Conference on Enterprise Information Systems**. [S. l.], 2019. v. 1, p. 535–544.
- VENCESLAU, A.; VIDAL, V.; ANDRADE, R. Context-driven abnormal semantic event recognition for healthcare applications. In: IEEE. **2021 IEEE International Conference on Pervasive Computing and Communications Workshops and other Affiliated Events (PerCom Workshops)**. [S. l.], 2021. p. 434–435.
- VENCESLAU, A. D.; VIDAL, V. M.; ANDRADE, R. M.; MAIA, J. G. R.; SILVA, J. W. F. da. Seact: Semantic adaptive segmentation of sensor data streams for human activity recognition. In: SBC. **Anais do XXXVII Simpósio Brasileiro de Bancos de Dados**. [S. l.], 2022. p. 317–329.
- WAN, J.; O'GRADY, M. J.; O'HARE, G. M. Dynamic sensor event segmentation for real-time activity recognition in a smart home context. **Personal and Ubiquitous Computing**, Springer, v. 19, n. 2, p. 287–301, 2015.
- WANG, Y.; CAO, K. A proactive complex event processing method for large-scale transportation internet of things. **International Journal of Distributed Sensor Networks**, SAGE Publications Sage UK: London, England, v. 10, n. 3, p. 159052, 2014.
- WOHLIN, C. Guidelines for snowballing in systematic literature studies and a replication in software engineering. In: **Proceedings of the 18th international conference on evaluation and assessment in software engineering**. [S. l.: s. n.], 2014. p. 1–10.
- WOHLIN, C.; RUNESON, P.; HÖST, M.; OHLSSON, M. C.; REGNELL, B.; WESSLÉN, A. **Experimentation in software engineering**. [S. l.]: Springer Science & Business Media, 2012.
- XPLORE, I. **IEEE Xplore Digital Library**. 2021. Disponível em: <https://ieeexplore.ieee.org>. Acesso em: 07-Abril-2021.

YE, J.; STEVENSON, G.; DOBSON, S. Usmart: An unsupervised semantic mining activity recognition technique. **ACM Transactions on Interactive Intelligent Systems (TiIS)**, ACM New York, NY, USA, v. 4, n. 4, p. 1–27, 2014.

YE, J.; STEVENSON, G.; DOBSON, S. Kcar: A knowledge-driven approach for concurrent activity recognition. **Pervasive and Mobile Computing**, Elsevier, v. 19, p. 47–70, 2015.

YIN, J.; YANG, Q.; PAN, J. J. Sensor-based abnormal human-activity detection. **IEEE Transactions on Knowledge and Data Engineering**, IEEE, v. 20, n. 8, p. 1082–1090, 2008.

ZHANG, Z. Introduction to machine learning: k-nearest neighbors. **Annals of translational medicine**, AME Publications, v. 4, n. 11, 2016.

## APÊNDICE A – REGRAS DE INFERÊNCIA

Na Tabela 15 a seguir são listadas as regras de inferência definidas pelo algoritmo de geração de regras Algoritmo 1 na Seção 5.3.4 e utilizadas no experimento proposto na Seção 6.2.

Tabela 15 – Regras de Inferência em SeAct.

```

@prefix rdf: <http://www.w3.org/1999/02/22-rdf-syntax-ns>
@prefix rdf: <http://www.w3.org/1999/02/22-rdf-syntax-ns>
@prefix owl: <http://www.w3.org/2002/07/owl>
@prefix xsd: <http://www.w3.org/2001/XMLSchema>
@prefix rdfs: <http://www.w3.org/2000/01/rdf-schema>
@prefix ACTION: <http://www.action.onto/ACTION.owl>
[rule1:(?user ACTION:hasEvent ?event0),
(?event0 rdf:type ACTION:Event),
(?event0 ACTION:hasValue "Door"),
(?event0 ACTION:relatedTime ?time0),
(?time0 ACTION:hasValue ?tval0),
(?user ACTION:hasEvent ?event1),
(?event1 rdf:type ACTION:Event),
(?event1 ACTION:hasValue "HallBedroom"),
(?event1 ACTION:relatedTime ?time1),
(?time1 ACTION:hasValue ?tval1),
makeTemp(?activity)
->
(?activity rdf:type ACTION:Activity),
(?user ACTION:hasActivity ?activity),
(?activity ACTION:hasValue "GoToBed"),
(?activity ACTION:relatedTime ?time1),
(?activity ACTION:composedOf ?event0),
(?event0 ACTION:partOf ?activity),
(?activity ACTION:composedOf ?event1),
(?event1 ACTION:partOf ?activity)]

```