

Um Modelo para Acompanhamento de Pessoas com Doença de Alzheimer utilizando Análise de Históricos de Contextos

A Model for Monitoring People with Alzheimer's Disease using Context Histories Analysis

Savanna Denega Machado¹, Jorge Luis Victória Barbosa¹, João Elison da Rosa Tavares¹, Márcio Garcia Martins¹

¹Universidade do Vale do Rio dos Sinos (UNISINOS)
São Leopoldo, RS – Brasil

savannadm@edu.unisinos.br, {jbarbosa, joaoer, marciog}@unisinos.com

Abstract. *This article presents a model considering physiological data received from external applications, making it possible to identify dangerous behaviors of patients with Alzheimer's Disease (AD). The main scientific contribution of this work is the specification of a model focusing on AD using the analysis of Context Histories and Context Prediction. DCARE is based on the experimental research method, focused on understanding the disease and finding solutions that minimize its impact on the daily monitoring of patients. In addition, a simulator was created, which generates datasets to perform tests of the model, complementarily an ontology was proposed for the treatment of contexts in the subject of Alzheimer's. This article consists of an extended version of the work published at the Brazilian Symposium on Information Systems (SBSI) in 2021. The scenarios used in the construction of the model were elaborated from interviews with five specialists in the care of AD patients. The tests were performed with a dataset of 1026 samples provisioned by the simulator proposed by this work. The results revealed that the predictions of the model's scenarios reached the objective of the work, achieving an accuracy of 97.44%.*

Keywords. *Alzheimer's disease, Context Histories, Context Prediction, Internet of Things for Healthcare, Patient monitoring.*

Resumo. *Este artigo apresenta um modelo que considera dados fisiológicos recebidos de aplicativos externos, que possibilitam a identificação de possíveis comportamentos perigosos de pacientes com a Doença de Alzheimer (DA). A principal contribuição científica deste trabalho é a especificação de um modelo com foco na DA a partir da análise de Históricos de Contextos e Predição de Contextos. O modelo proposto DCARE é baseado no método de pesquisa experimental, para entender a doença e encontrar soluções que minimizem seu impacto no acompanhamento diário dos pacientes. De modo complementar, foi*

desenvolvido um simulador, que gera datasets para realizar testes do modelo, além de ser proposta uma ontologia para o tratamento de contextos na temática do Alzheimer. Este artigo consiste em uma versão estendida do trabalho publicado no Simpósio Brasileiro de Sistemas de Informação (SBSI) em 2021. Os cenários utilizados na construção do modelo foram elaborados a partir de entrevistas com cinco especialistas no atendimento a pacientes com DA. Os testes foram realizados com a massa de dados com 1026 amostras geradas pelo simulador proposto por este trabalho. Os resultados revelaram que as previsões dos cenários do modelo atingiram o objetivo do trabalho, obtendo 97,44% de acurácia.

Palavras-Chave. *Doença de Alzheimer, Históricos de Contextos, Internet das Coisas para Cuidados com a Saúde, Monitoramento de Pacientes, Predição de Contextos.*

1. Introdução

Segundo a *World Health Organization* [WHO 2022a], cerca de 50 milhões de pessoas ao redor do mundo são portadoras da doença de Alzheimer ou de algum tipo de demência. De acordo com a Organização Pan-Americana da Saúde [OPAS 2022], o Alzheimer está na lista entre uma das dez principais doenças causadoras de mortes no mundo. O Alzheimer é uma das doenças vertentes da demência, em que se caracteriza por ser uma síndrome – geralmente de natureza crônica ou progressiva – que não há cura ou tratamento, na qual há deterioração da função cognitiva (ou seja, a capacidade de processar o pensamento), além do que se pode esperar do envelhecimento normal. O comprometimento da função cognitiva geralmente é acompanhado e, às vezes, precedido de deterioração do controle emocional, comportamento social ou motivação. Embora a demência afete principalmente pessoas idosas, a demonstração de sintomas pode começar a ocorrer mesmo antes da etapa do envelhecimento, o que influencia no fato de que há quase 10 milhões de novos casos a cada ano ao redor do mundo [Association 2022]. Prevê-se que o número total de pessoas com demência atinja 82 milhões em 2030 e 152 milhões em 2050, e, parte significativa desse aumento é atribuível ao número crescente de pessoas com demência que vivem em países de baixa a média renda [AZ 2015].

A demência tem um impacto físico, psicológico, social e econômico, não apenas nas pessoas com a doença, mas também em seus cuidadores, famílias e sociedade em geral, sendo uma das principais causas de incapacidade e dependência entre os idosos em todo o mundo [WHO 2022a]. Cuidadores que prestam assistência a indivíduos com demência frequentemente se sentem estressados, frustrados com a quantidade de tempo necessária (nos cuidados aos pacientes) e emocionalmente desafiados. Além de que, a função cognitiva pode diminuir progressivamente ao longo do tempo nos pacientes, em variações que flutuam ao longo do dia ou a longo prazo, à medida que o sistema neurológico é utilizado [Burlison et al. 2018]. Esses comportamentos são difíceis de serem gerenciados pelos cuidadores e estão positivamente correlacionados com o sofrimento do cuidador [Khoo et al. 2013]. Eles também contribuem para o aumento do custo dos cuidados para com os pacientes e são a principal razão da institucionalização dos cuidados [Brodaty et al. 2014] [Murman et al. 2002a]. Em 2015, o custo total para os cuidados da demência foi estimado em 818 bilhões de dólares, equivalente a 1,1% do Produto Interno

Bruto (PIB) global. O custo total em relação ao PIB teve variação de 0,2% nos países de baixa e média renda e 1,4% nos países de alta renda [WHO 2022a].

Pelo fato do Alzheimer ser uma doença que é apenas detectada após o aparecimento dos primeiros sintomas, surgem soluções de acompanhamento com uso de dispositivos eletrônicos para cuidado destes pacientes nas mais diversas fases da doença, portanto, a tecnologia apresenta-se como uma possibilidade no suporte de cuidados paliativos para os pacientes. Segundo [Burlison et al. 2018], trabalhos de pesquisa recentes sobre Tecnologias da Informação e Comunicação¹ (TICs) para tratamento de demência demonstraram como a incorporação bem-sucedida de tecnologia nas práticas cotidianas implica em um conjunto de julgamentos e atitudes de valor sobre a melhor forma de cuidar e tomar decisões por outra pessoa.

A maioria dos cuidadores que usam tecnologias como suporte de tratamento, obtiveram benefícios para seus pacientes de pelo menos uma Atividade da Vida Diária (AVD) (86%). As AVDs com as quais os cuidadores costumam ajudar são: levantar e deitar/sentar em camas e cadeiras (73%), vestir-se (61%) e alimentar-se (52%). Cerca de um em cada três cuidadores auxilia no banho (37%) ou no banheiro (34%), e 26% ajudam a lidar com a incontinência [National Alliance for Caregiving 2011]. A WHO desenvolveu um plano mundial de ação que propõe que até 2025 a produção global de pesquisa sobre demência tenha o dobro de publicações científicas, e que sobretudo, 50% dos países colem rotineiramente dados sobre os principais indicadores de demência e que 75% dos países tenham suporte para prestadores de cuidados de demência [WHO 2022b]. A prevalência alarmante da doença de Alzheimer e a ausência de qualquer tratamento efetivo fizeram desta doença uma pauta importante, destacada como uma prioridade pelas oito nações mais ricas do mundo (G8) [Vugt et al. 2005].

Este artigo consiste em uma versão estendida do texto publicado por [Machado et al. 2021] no Simpósio Brasileiro de Sistemas de Informação em 2021. O artigo propõe o DCARE, um modelo para monitoramento de pacientes com Alzheimer, buscando sintetizar as necessidades e características que compõem uma melhor abordagem para sua validação. A principal contribuição científica do DCARE é a especificação de um modelo computacional a ser o primeiro a utilizar a análise sobre Históricos de Contextos e Predição de Contextos com foco na doença de Alzheimer. A partir do modelo, foi desenvolvido um protótipo. Posteriormente, os testes foram realizados com base nos *datasets* gerados pela ferramenta *DCARE Dataset Simulator*, desenvolvida em conjunto neste trabalho.

Este artigo está organizado em 7 seções. A Seção 2 apresenta o referencial teórico do trabalho. A Seção 3 discute e compara os trabalhos relacionados. A Seção 4 descreve o modelo DCARE. A Seção 5 detalha os aspectos de implementação. A metodologia de avaliação é descrita na Seção 6, enquanto a Seção 7 apresenta a conclusão do trabalho.

2. Referencial Teórico

Esta seção apresenta conceitos fundamentais que envolvem o desenvolvimento do modelo computacional para monitoramento de pessoas com a doença de Alzheimer, DCARE,

¹<https://en.unesco.org/themes/ict-education>

com a finalidade de elucidar as áreas de estudos. Foram elencados aspectos humanos e tecnológicos presentes na literatura que contribuem para o entendimento deste trabalho.

2.1. Doença de Alzheimer

O Alzheimer é uma das doenças vertentes da demência, em que se caracteriza por ser uma síndrome - geralmente de natureza crônica ou progressiva - que não há cura ou tratamento, na qual há deterioração da função cognitiva (ou seja, a capacidade de processar o pensamento), além do que se pode esperar do envelhecimento normal. A doença afeta a memória, o pensamento, a orientação, a compreensão, o cálculo, a capacidade de aprendizado, a linguagem e o julgamento, porém a consciência não é afetada. O comprometimento da função cognitiva geralmente é acompanhado e, às vezes, precedido de deterioração do controle emocional, comportamento social ou motivação. A doença de Alzheimer é a forma mais comum de demência e pode contribuir para 60-70% dos casos [AZ 2022].

Indivíduos com Alzheimer e outras formas de demência geralmente passam por um período de sintomas comportamentais e psicológicos significativos de demência (*behavioral and psychological symptoms of dementia - BPSD*) [Nesbitt et al. 2018a]. De acordo com [Cohen-Mansfield 2008], os *BPSDs* são geralmente divididos em categorias, tais como agitação, agressão física e não-física e agitação verbal. Comportamentos não-físicos incluem despir, exprimir, esconder coisas e sair do comportamento de busca. Os comportamentos fisicamente agressivos incluem morder, bater, chutar, empurrar, coçar e avanços sexuais indesejados. Também pode haver agitação verbal, como xingamentos, gritos e repetidas ações de atenção.

Apenas no Brasil, há mais de 30 milhões de pessoas acima dos 60 anos, de acordo com dados do Instituto Brasileiro de Geografia e Estatística (IBGE) de 2013, e acredita-se que quase 2 milhões de pessoas têm demências, sendo que cerca de 40 a 60% delas são do tipo Alzheimer [de Geografia e Estatística IBGE 2022].

Embora a demência afete principalmente pessoas idosas, a demonstração de sintomas pode começar a ocorrer mesmo antes desta etapa do envelhecimento, o que influencia no fato de que há quase 10 milhões de novos casos a cada ano ao redor do mundo [Association 2022].

2.2. Impactos do Alzheimer

A demência tem um impacto físico, psicológico, social e econômico, não apenas nas pessoas com demência, mas também em seus cuidadores, famílias e sociedade em geral, sendo uma das principais causas de incapacidade e dependência entre os idosos em todo o mundo. Frequentemente, há falta de consciência e entendimento da demência, resultando em estigmatização e barreiras ao diagnóstico e atendimento. O impacto da demência nos prestadores de cuidados, na família e na sociedade em geral pode ser físico, psicológico, social e econômico [WHO 2022a].

Segundo [WHO 2022a], cerca de 50 milhões de pessoas ao redor do mundo são portadoras da doença de Alzheimer ou de outro tipo de demência. De acordo com [OPAS 2022], o Alzheimer está na lista entre uma das dez principais doenças causadoras

de mortes no mundo. Prevê-se que o número total de pessoas com demência atinja 82 milhões em 2030 e 152 milhões em 2050, e, grande parte desse aumento é atribuível ao número crescente de pessoas com demência que vivem em países de baixa e média renda [AZ 2015].

2.3. Tecnologias para o Monitoramento e o Uso de Dispositivos

Comportamentos *BPSDs* são difíceis de serem gerenciados pelos cuidadores e estão positivamente correlacionados com o sofrimento do cuidador [Tan et al. 2005]. Eles também contribuem para o aumento do custo dos cuidados para pessoas com demência e são a principal razão da institucionalização dos cuidados [Nesbitt et al. 2018b] [Vugt et al. 2005] [Murman et al. 2002b]. Problemas comportamentais são uma preocupação de segurança para familiares e cuidadores profissionais, bem como para outros idosos que vivem em ambientes comunitários. Existem métodos não farmacológicos validados usados para gerenciar o *BPSD*. Esses métodos incluem redirecionamento, musicoterapia, socialização individual, arteterapia e terapia assistida por animais [Cohen-Mansfield et al. 2012]. Uma questão crucial sobre o *BPSD* é o reconhecimento pelo cuidador de gatilhos ou eventos que geralmente precedem um comportamento indesejado [Pillemer et al. 2011] [Ferrah et al. 2015]. Mesmo que os gatilhos não possam ser identificados, o simples reconhecimento de que um paciente está agitado pode ser benéfico, pois um cuidador pode ser chamado conforme necessário. Deve-se notar que os cuidadores geralmente não estão presentes no início desses gatilhos.

Pelo fato do Alzheimer ser uma doença que é apenas detectada depois que começam a aparecer os sintomas, surgem soluções de acompanhamento com uso de dispositivos para cuidado destes pacientes nas mais diversas fases da doença, portanto, a tecnologia apresenta-se como uma possibilidade no suporte de cuidados paliativos para os pacientes. Segundo [Burleson et al. 2018], trabalhos de pesquisa recentes sobre Tecnologias da Informação e Comunicação¹ (TICs) para tratamento de demência, demonstraram como a incorporação bem-sucedida de tecnologia nas práticas cotidianas implica em um conjunto de julgamentos e atitudes de valor sobre a melhor forma de cuidar e tomar decisões por outra pessoa. Ao longo dos anos, o uso de dispositivos inteligentes e sensores vestíveis aumentou drasticamente no campo da saúde. Esses sensores são usados para uma variedade de aplicações, desde a segurança até o monitoramento de medidas de saúde, como qualidade e quantidade do sono [Fowler et al. 2016]. A maioria dos cuidadores que usam tecnologia como suporte obtiveram benefícios para seus pacientes de pelo menos uma Atividade da Vida Diária (AVD). Em média, os cuidadores prestam assistência em três das seis atividades listadas. As AVDs com as quais os cuidadores costumam ajudar são: levantar e deitar/sentar em camas e cadeiras (73%), vestir-se (61%) e alimentar-se (52%). Cerca de um em cada três (cuidadores) ajuda no banho (37%) ou no banheiro (34%), e 26% ajudam a lidar com a incontinência [National Alliance for Caregiving 2011]. A WHO desenvolveu um plano mundial de ação que propõe que até 2025 a produção global de pesquisa sobre demência tenha o dobro de publicações científicas, e que sobretudo, 50% dos países colem rotineiramente dados sobre os principais indicadores de demência e 75% dos países tenham suporte para

¹<https://en.unesco.org/themes/ict-education>

prestadores de cuidados de demência [WHO 2022b]. A prevalência alarmante da doença de Alzheimer e a ausência de tratamento efetivo fizeram desta doença uma questão importante, destacada como uma prioridade pelas nações do G8 [Vugt et al. 2005].

2.4. Contextos

Para a realização do processamento de dados são abordados os conceitos de influência dos comportamentos dos pacientes, os lugares significantes e o deslocamento entre eles, ou seja, consideram-se padrões de mobilidade. Locais significantes são aqueles que tem um significado singular durante a rotina diária. No modelo computacional, estes locais são nomeados como locais semânticos. O tempo utilizado em locais semânticos e seu deslocamento, junto com as atividades reconhecidas do usuário (ficar parado, caminhar, correr, dormir, etc.), caracterizam o comportamento dos pacientes. Para identificar contextos relevantes, são usados os conceitos de Reconhecimento de Contexto, Históricos de Contextos e Predição de Contextos.

Segundo [Barbosa 2015], Reconhecimento de Contexto é uma fonte de informação que permite que os aplicativos se tornem cientes das interações entre humanos e o ambiente. Em suma, segundo [Dey et al. 2001], contexto é qualquer informação que pode ser usada para caracterizar a situação de entidades (por exemplo pessoa, lugar ou objeto) que são consideradas relevantes para a interação entre um usuário e um aplicativo, incluindo o usuário e o próprio aplicativo. Além disso, [Dey et al. 2001] destacam que esta descrição inclui dados de localização que nos permitem considerar a mobilidade dos usuários para desenvolver serviços contextualizados e adaptáveis. O Reconhecimento de Contexto é organizado em diferentes níveis de abstração. Existem dados de contexto brutos, contexto de baixo nível e contexto de alto nível. Cada nível de abstração depende da quantidade de interpretação que foi aplicada [da Rosa et al. 2016], ou seja, a representação de contexto superior tende a ser simbólica, enquanto as representações inferiores são frequentemente numéricas [Sigg 2008a]. Em seu trabalho, [Dey et al. 2001] descrevem que os aplicativos sensíveis ao contexto identificam dados com os termos: para quem é, onde está, quando e o que é dos usuários. Essas informações são utilizadas para determinar o por quê de uma situação estar ocorrendo. Assim, os autores propuseram quatro categorias básicas para modelar o contexto: (1) identidade; (2) localização; (3) tempo; e (4) atividade. Esses tipos de contexto não apenas respondem às questões de quem, onde, quando e o quê, mas também agem como índices para outras fontes de informação contextual.

Histórico de Contextos é um acompanhamento de dados que salva as informações do Reconhecimento de Contexto para serem analisados posteriormente e utilizados para tomada de decisões atuais ou futuras [Filippetto et al. 2021] [Martini et al. 2021] [Aranda et al. 2021]. O registro das atividades executadas por um usuário, acompanhado de informações sobre a localização, permite gerar históricos de contextos visitados ao longo do tempo [Silva et al. 2010] [Smith 2008]. Este histórico também pode ser chamado de trilha, como em [Driver and Clarke 2008]. Para [Driver and Clarke 2004] uma trilha é, no nível mais geral, uma coleção de localizações acompanhadas de informações associadas e uma ordem recomendada de visitação. Os autores utilizam a metáfora da trilha para capturar as atividades diárias de um usuário e adaptar o fun-

cionamento de aplicações móveis sensíveis ao contexto, considerando-se o histórico de atividades e localizações visitados pelo usuário.

A abordagem de Predição de Contexto constitui um método de previsão flexível que é especialmente adequado para encontrar padrões de contexto típicos em uma série temporal de contextos. A extensão dos padrões de contexto típicos é arbitrária, mas limitada pela extensão dos Históricos de Contextos [da Rosa et al. 2016]. Sobretudo, Predição de Contexto é uma análise realizada sobre os dados de Históricos de Contextos para gerar previsões de comportamentos. A obtenção dos contextos futuros dos usuários é feita por meio de técnicas de previsão. Com base nos históricos dos usuários e em seus contextos atuais, os algoritmos preveem os contextos que provavelmente descreverão a situação futura dos usuários [Sigg et al. 2011]. Segundo [Sigg 2008b], a predição de contextos pode ser usada por aplicativos para estender o conhecimento sobre um contexto observado no futuro. Em outras palavras, para adaptar seu comportamento a eventos que provavelmente ocorrerão no futuro.

2.5. Ontologia

Segundo [Keet 2018], uma forma rápida e informal de esclarecer o que é uma ontologia em computação seria compor um arquivo de texto contendo conhecimento estruturado sobre um particular domínio de conhecimento. De modo que este arquivo é usado como um componente de um sistema de informação inteligente.

Além disso, [Keet 2018] afirma que as ontologias têm sido usadas para resolver problemas de integração de dados provendo um padronizado e bem definido vocabulário que é usado de modo que o software entende este modelo de dados que caracteriza um domínio, estabelecendo um padrão de referência para os dados acessados por diferentes camadas da arquitetura de um sistema complexo.

Portanto, como um artefato de software, uma ontologia representa uma formalização de um domínio que concentra uma porção de conhecimento, através de entidades (classes), relacionamentos e elementos (instâncias). Uma ontologia, ainda, como um artefato de engenharia de software pode ser apresentada no formato *Web Ontology Language (OWL)*, estando apta a ser computacionalmente processada, especialmente quando representada no padrão *RDF/XML* [Keet 2018]. As representações gráficas do *OntoGraf* do Protégè [Protégé 2022] ou diagramas de classe UML aproximados [da Silva 2009] são as representações mais utilizadas para a visualização de ontologias.

3. Trabalhos Relacionados

A pesquisa para identificar o estado da arte no tema segue os critérios descritos na Subseção 3.1, e foi conduzida relacionando três principais perspectivas que fazem referência ao tema deste trabalho: (1) monitoramento de sinais vitais; (2) monitoramento de localização; e (3) análise dos dados coletados no monitoramento. A análise dos artigos resultou em cinco trabalhos que foram selecionados como base para a pesquisa, que foram analisados e descritos resumidamente na Subseção 3.2. Na Subseção 3.3 é apresentado o diferencial do trabalho proposto.

3.1. Critérios para Escolha dos Trabalhos Relacionados

A realização das análises das pesquisas, para identificar o estado da arte, foi realizada utilizando-se como base a revisão sistemática publicada no artigo de [Machado and Barbosa 2020]. Os trabalhos foram selecionados através de pesquisas nas bases de dados de acordo com a Tabela 1. Destes, *PubMed Central* e *JMIR* destacam-se como bases literárias na área da saúde e ciências da natureza, enquanto as demais bases são referência em computação.

Table 1. Bases de dados exploradas na revisão sistemática.

| Base de dados | URL de acesso |
|--|---|
| <i>ACM Digital Library</i> | https://dl.acm.org |
| <i>IEEE Xplore Digital Library</i> | https://ieeexplore.ieee.org/Xplore/home.jsp |
| <i>Journal of Medical Internet Research (JMIR)</i> | https://www.jmir.org/ |
| <i>PubMed Central</i> | https://www.ncbi.nlm.nih.gov/pmc/ |
| <i>Science Direct</i> | https://www.sciencedirect.com/ |
| <i>Springer Library</i> | https://link.springer.com/ |

As pesquisas foram baseadas em termos sinônimos ao assunto do trabalho e suas derivações, definidos como ("Alzheimer" OR "Alzheimer's Disease" OR "Alzheimer Patients" OR "Alzheimer's Care") AND ("care" OR "detect" OR "track" OR "monitoring" OR "Assistive Technology" OR "Patient Monitoring" OR "device" OR "smartphone" OR "smartphones" OR "mobile application" OR "mobile" OR "mHealth" OR "app"). Esses grupos de termos foram intercalados para aumentar o alcance da pesquisa. A escolha dos trabalhos levou em consideração se empregavam os seguintes elementos: a doença de Alzheimer; recursos de monitoramento de sinais vitais; e análise de dados, resultando em melhores cuidados aos pacientes.

3.2. Descrição dos Trabalhos Relacionados

Nesta seção são descritos os trabalhos relacionados que foram utilizados como base de comparação para o desenvolvimento do trabalho proposto.

3.2.1. *Development of a sensor-based behavioral monitoring solution to support dementia care*

O trabalho apresentado por [Thorpe et al. 2019] tem como principal objetivo a medição da mobilidade de pessoas que possuem demência. A mobilidade reduzida pode apresentar um ciclo de *feedback* perigoso, inibindo o envolvimento e a estimulação social, agravando o declínio cognitivo e os sintomas depressivos que contribuem para uma maior redução da mobilidade. O modelo computacional utiliza sensores disponíveis em tecnologias acessíveis aos usuários, como *smartphones* e *smartwatches*, para calcular um conjunto de métricas de mobilidade espacial, temporal e baseada em contagem de passos. Após receber os dados, o servidor realiza uma análise, obtendo padrões de comportamento e relacionando com possíveis padrões perigosos e que podem trazer algum dano para a saúde e segurança paciente. Para validar a eficácia do modelo, a aplicação foi testada através de um experimento com pacientes de centros de idosos na cidade de pesquisa, no

país da Dinamarca. A avaliação mostrou que a solução de monitoramento comportamental mede com sucesso as trajetórias de viagem e métricas de mobilidade a partir de dados de localização e extrai dados de atividades durante a viagem entre os locais.

3.2.2. *Design of a GPS Monitoring System for Dementia Care and its Challenges in Academia-Industry Project*

O trabalho desenvolvido por [Wan et al. 2016], é um sistema a ser utilizado para monitoramento no processo de tratamento da demência, para apoiar os cuidadores no atendimento as necessidades específicas de cada pessoa com os sintomas de perda cognitiva e perda de memória. O protótipo final consistiu em rastreadores *GPS* para os pacientes transportarem, um servidor para receber informações dos rastreadores e configurá-los remotamente, um portal da web para gerenciar os rastreadores e monitorar locais em tempo real e um aplicativo para iPhone para monitorar os locais de tempo em movimento. Os usuários finais no pré-estudo consideraram o processo e o produto benéficos e apreciaram particularmente a tecnologia que foi utilizada, sendo facilmente de ser instalada e monitorada. O artigo trouxe uma contribuição ao desenvolvimento de uma perspectiva orientada a prática, na qual o estudo das práticas do usuário e o estudo das práticas organizacionais analisadas em conjunto podem proporcionar uma melhor maneira pela qual os resultados do projeto são alcançados e promover a discussão sobre como “melhores práticas” podem ser alcançadas para o resultado final.

3.2.3. *Reliability of Wearable Sensors to Detect Agitation in Patients with Dementia: A Pilot Study*

O trabalho de Nesbitt et al. [Nesbitt et al. 2018a] descreve um projeto em que são utilizados dispositivos já disponíveis no mercado para captar informações de dados vitais dos pacientes via sensores. O objetivo é monitorar a localização de indivíduos e medir alterações físicas e fisiológicas, como movimentos de membros, vocalizações e frequência cardíaca que ocorrem durante o estado de agitação. Indivíduos com Alzheimer e outras formas de demência geralmente passam por um período de sintomas comportamentais e psicológicos significativos de demência (*BPSD*). A estrutura do projeto foi desenvolvida tendo como base um software que utiliza quatro sensores: um acelerômetro triaxial, um monitor de batimentos cardíacos, um microfone e *Bluetooth*. O acelerômetro é usado para medir o movimento dos membros, especificamente o movimento dos braços. O microfone captura o áudio, que é usado para medir o nível e o tom dos decibéis, além de analisar as palavras faladas. A análise do fluxo de áudio é feita com base na fala e tom, usando sistemas de software de terceiros. O *Bluetooth* nos ajuda a determinar a localização dentro da instalação. O estudo considerou que as emoções experimentadas por pessoas com *BPSD* são reais, e o desenvolvimento de ferramentas para identificar ou prever rapidamente explosões que melhorariam seu bem-estar geral. Assim, métodos para intervir mais cedo quando ocorrerem problemas de comportamento podem reduzir o estresse do cuidador, o custo geral dos cuidados e potencialmente atrasar a institucionalização e reduzir a quantidade de carga de medicamentos prescrita para indivíduos com *BPSD*.

3.2.4. *CLONE: A promising system for the remote monitoring of Alzheimer's patients an experimentation with a wearable device in a village for Alzheimer's care*

O projeto *CLONE* desenvolvido por [Amato et al. 2018] tem como objetivo explorar a aplicação de tecnologias de monitoramento remoto capazes de detectar o início de crises em pacientes afetados pela doença de Alzheimer, que podem aliviar a carga psicológica sofrida pelos cuidadores. O modelo computacional desenvolvido, chamado *Eclipse*, utiliza uma pulseira inteligente equipada com os sensores necessários para monitorar os seguintes parâmetros: Pressão do volume sanguíneo (PAV), intervalo de batimentos (IBI), frequência cardíaca (FC), atividade eletrodérmica (EDA), aceleração em 3 eixos e temperatura da pele. A partir da realização dos experimentos, foi possível coletar dados vitais e comportamentais de idosos afetados pela doença de Alzheimer durante a vida cotidiana e explorar oportunidades para encontrar relações entre as tendências fisiológicas e o aparecimento de crises. As descobertas em potencial nessa direção, possibilitaram a coleta de informações, e em trabalhos futuros permitiram desenvolver um sistema capaz de antecipar ou notificar a ocorrência de crises por meio de tecnologias de monitoramento remoto.

3.2.5. *Wearable technology for detecting significant moments in individuals with dementia*

O trabalho desenvolvido por [Lai Kwan et al. 2019] tem como objetivo detectar momentos significativos de indivíduos com demência, tornando visível o que é mais significativo para eles e mantendo um senso de conexão interpessoal entre seus cuidadores e familiares. O projeto tem como base sensores vestíveis estabelecidos nos padrões de sinais psicológicos, atividades eletrodérmicas e temperatura da pele que é utilizado através de um dispositivo vestível chamado Sensor de Ponto Triplo (TPS). O modelo consumido, chamado de Tecnologia Assistiva (*intelligent assistive technology - IAT*), foi utilizado para a detecção de momentos significativos com base em padrões de alterações fisiológicas do paciente. Os parâmetros do *IAT* são adaptados aos padrões de resposta fisiológica de cada indivíduo, por meio de um processo iterativo de incorporação de *feedback* de vídeos extraídos de momentos significativos do paciente. Posteriormente a coleta dos dados estes são analisados pelo software *Events Finder*, desenvolvido pela equipe do projeto, que é um conjunto de ferramentas construídas com a tecnologia *MATLAB*, e possibilita realizar a análise e relacionar estes dados com os situações específicas vivenciadas. Após a conclusão do experimento, foi possível detectar momentos de importância vivenciados de acordo com relatos subjetivos com 70% de exatidão. Esses momentos foram formados por significados físicos e emocionais (por exemplo, experiências de dor ou ansiedade) e significância interpessoal (por exemplo, momentos de conexão elevada).

3.3. Diferenciais do DCARE

Para realizar a comparação entre os trabalhos relacionados e o trabalho proposto, a lista de critérios a seguir foi utilizada:

- Acompanhamento de sinais vitais: Realiza coleta de dados de sinais vitais por meio de um *wearable*, que é utilizado diariamente pelo paciente;

- Acompanhamento por geolocalização: Realiza coleta de dados de geolocalização, que é utilizado diariamente pelo paciente;
- Análise de dados: Realiza análise sobre os dados coletados;
- Resultado da análise de dados momentânea: Realiza a análise dos dados coletados de forma instantânea, de modo a não operar com análise posterior;
- Alerta de perigo: Realiza acionamento de alerta em tempo real caso o paciente esteja comprometido, com algum perigo à sua saúde ou segurança;
- Predições de ações: Predições de comportamentos de acordo com base nos dados históricos.

Todos os trabalhos apresentados compreendem o critério de análise de dados. As soluções apresentadas nos trabalhos de [Thorpe et al. 2019] e [Wan et al. 2016] visam a fazer referência especificamente ao monitoramento do paciente sobre a sua geolocalização, identificando sua posição para controle dos seus cuidadores, não abrangendo o restante dos critérios especificados na comparação junto ao DCARE. Outro ponto a considerar é que apenas a solução do trabalho de [Thorpe et al. 2019] apresenta uma abordagem para validar os aspectos vitais a fim de legitimar as ações necessárias para garantir a segurança e saúde do paciente (alerta de perigo), também não abrangendo o restante dos critérios especificados na comparação junto ao DCARE.

No que diz respeito aos trabalhos realizados por [Nesbitt et al. 2018a] e [Amato et al. 2018], as definições demonstram que embora também seja utilizado um conjunto de sensores, realizada a análise de dados e posteriormente apresentação dos resultados, abrangendo alguns dos critérios, os modelos computacionais propostos nestes trabalhos não apresentam em sua arquitetura uma abordagem para processar as diversas desordens mentais e comportamentos que um paciente portador da doença de Alzheimer pode acionar, não abrangendo um dos principais critérios proposto no modelo DCARE, que é garantir que as informações, já processadas, sejam exibidas imediatamente em tempo real para o cuidador, e que em caso de perigo um alerta seja enviado.

No modelo computacional desenvolvido por [Lai Kwan et al. 2019] é empregada a sensibilidade ao contexto para correlacionar os sinais vitais do usuário com a análise da saúde mental, com objetivo de identificar em quais situações o usuário possa ter atingido reações de comprometimento afetivo com seus cuidadores ou familiares. Nesse caso, nenhum tipo de avaliação é enviada ao cuidador, portanto, é um modelo em que a informação é analisada posteriormente e somente utilizada para fim de identificação de picos da saúde mental. Sendo assim, não é realizado o monitoramento de dados vitais, e o envio de informações não é realizado de forma imediata ao cuidador em caso de perigo à saúde do paciente, não abrangendo os requisitos indicados neste sentido.

A Figura 1 apresenta a comparação entre os trabalhos relacionados analisados e o trabalho proposto, desta forma, é possível observar que os modelos apresentados não atingem os objetivos propostos para completar os aspectos gerais de monitoramento de dados vitais, monitoramento de localização *GPS*, análise e resultados de dados momentânea, apresentação de dados para o cuidador e alerta de perigo imediato sobre saúde do paciente ou no modelo de predição ao cuidador. Além disso, é importante destacar que nenhuma das obras estudadas considera a realização de predições sobre comportamentos.

| Critério | Thorpe et al. 2019 | Wan et al. 2016 | Nesbitt et al. 2018b | Amato et al. 2018 | Lai Kwan et al. 2019 | DCARE |
|--|--------------------|-----------------|----------------------|-------------------|----------------------|-------|
| Acompanhamento de sinais vitais | Não | Não | Sim | Sim | Sim | Sim |
| Acompanhamento por geolocalização | Sim | Sim | Não | Não | Não | Sim |
| Resultado da análise de dados momentânea | Sim | Sim | Não | Não | Não | Sim |
| Alerta de perigo | Sim | Não | Não | Não | Não | Sim |
| Predições de ações | Não | Não | Não | Não | Não | Sim |

Figure 1. Comparativo entre os trabalhos relacionados.

Portanto, a Seção 4 apresenta o DCARE, um modelo computacional que abrange os objetivos propostos para um acompanhamento geral, processamento de dados e envio de alertas ao cuidador em caso de perigo ao paciente. DCARE utiliza uma estrutura de Históricos de Contextos, que coleta as informações de contextos do ambiente. Posteriormente, realiza o processamento destas informações, gerando Predições de Contextos do usuário, sendo possível detectar, automaticamente, ações futuras, permitindo ao cuidador ter maior controle e cuidado com o paciente. A principal contribuição científica deste trabalho é a especificação de um modelo para acompanhamento de pessoas com a doença de Alzheimer durante as Atividades Vida Diária (AVDs), com a promoção de acesso a uma ferramenta para cuidados de saúde e segurança dos pacientes, além de contribuir com o desenvolvimento de um simulador de *datasets* com cenários de AVDs de pacientes com a doença de Alzheimer.

4. Modelo DCARE

Esta seção descreve o modelo computacional proposto para acompanhamento e cuidados a pacientes com a doença de Alzheimer. A seção está dividida em três subseções. Na Subseção 4.1 é detalhada a arquitetura do modelo e seus componentes; na Subseção 4.2 são apresentadas as entidades de contexto que compõem modelo; e por fim, na Subseção 4.3 é apresentado o detalhamento sobre a Predição de Contextos.

4.1. Arquitetura

O modelo DCARE foi projetado usando a modelagem técnica *TAM* (*Technical Architecture Modeling*), criada pela empresa *SAP* [SAP 2007]. A Figura 2 apresenta a arquitetura do modelo DCARE composta por atores (Paciente e Cuidador), acessos, bloco (Servidor Aplicação DCARE) e componentes. Os componentes do modelo aparecem na parte interna do bloco Servidor Aplicação DCARE.

A arquitetura presente no servidor da aplicação DCARE apresenta cinco componentes e um banco de dados. Primeiramente, a arquitetura apresenta a comunicação entre o modelo e a aplicação de disponibilização de dados, que é uma aplicação de projeto externo que disponibiliza as informações de localização *GPS* e sinais de frequência cardíaca do paciente coletados a partir de um *wearable*. O DCARE realiza requisições à aplicação de disponibilização de dados por meio de uma *API*, esta comunicação é realizada por meio do componente *Web Service*, que tem a responsabilidade de realizar a comunicação entre as aplicações externas. Após o recebimento dos dados, o componente

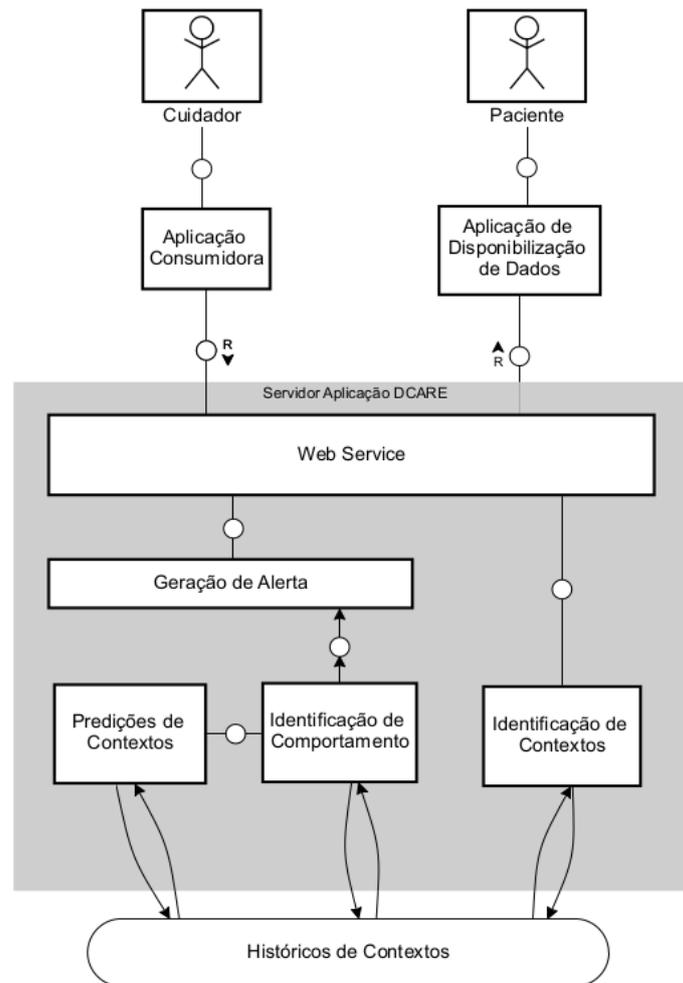


Figure 2. Arquitetura do DCARE.

de Identificação de Contextos realiza as operações de processamento de dados, identificando os contextos de modo padronizado e armazenando-os no componente de Históricos de Contextos (banco de dados).

O componente de Identificação de Comportamento apresenta métodos de processamento com base na utilização dos Históricos de Contextos para identificar comportamentos de pacientes relativos ao conceito de *BPSD* (*Behavioral and Psychological Symptoms of Dementia*). A análise de acordo com o comportamento, tem como base os critérios disponibilizados no trabalho de [Nesbitt et al. 2018a], em que indica que indivíduos com Alzheimer e outras formas de demência geralmente passam por um período de sintomas comportamentais e psicológicos significativos de demência (*BPSD*). De acordo com [Cohen-Mansfield 2008], os *BPSDs* são geralmente divididos em várias categorias, as mais comuns são agitação ou agressão física e não-física, e agitação verbal. Comportamentos não físicos incluem despir, exprimir,

esconder coisas e comportamento de busca. Os comportamentos fisicamente agressivos incluem morder, bater, chutar, empurrar, coçar e avanços sexuais indesejados. Também pode haver agitação verbal, como xingamentos, gritos e repetidas ações de atenção. Esses comportamentos são muito difíceis de serem gerenciados pelos cuidadores e estão positivamente correlacionados com o sofrimento do cuidador. De acordo com o trabalho de [Nesbitt et al. 2018a], a partir desses conceitos, é possível relacionar os dados extraídos através de um *wearable* com os sintomas mais comuns listados, elencando atividades de rotina ou possíveis comportamentos perigosos para a saúde e segurança do paciente. Assim, com a análise dos dados que são disponibilizados pela aplicação consumidora, é possível fazer uma comparação com os padrões já detectados pelo trabalho de [Nesbitt et al. 2018a], identificando qual é o tipo de comportamento que o paciente está realizando.

O componente de *Predições de Contextos* é desenvolvido com base no conceito de *Aprendizado de Máquina*, utilizado para realizar as predições de comportamentos futuros dos pacientes. O objetivo deste componente é auxiliar o cuidador, com a análise dos dados para que seja possível prever comportamentos perigosos à saúde e segurança do paciente.

Ao final do processamento dos dados, o DCARE envia os resultados para componente *gateway* *Geração de Alerta*. O componente de *Geração de Alerta* é construído com base na arquitetura de filas de mensagens. Fila de mensagens é um tipo componente de engenharia de software utilizado para a comunicação entre processos ou *threads* de um mesmo processo. Deste modo, quando os resultados das análises realizadas pelos componentes de *Identificação de Comportamento* e *Predições de Contexto* são finalizadas, estas informações são enviadas para a fila de mensagens que a aplicação do cuidador está conectada. A aplicação consumidora, construída externamente, que é utilizada pelo cuidador, realiza a requisição dos dados para o DCARE via *API* disponibilizada para acesso pelo componente *Web Service*. A aplicação consumidora recebe os dados processados pelo DCARE, e então, se encarrega de realizar a ação de alerta ao cuidador.

O aplicativo DCARE *Mobile* disponibiliza também um serviço de alerta, sendo esta parte da fase de *Intervenção* do modelo. A ação relacionada ao alerta apenas acontece se for identificada a necessidade de realização de uma intervenção na fase de *Identificação de Comportamento*. A intervenção caracteriza-se como um alerta para o aplicativo do *smartphone* que o cuidador está utilizando para realizar o monitoramento do paciente, avisando situações de perigo que o usuário possa se encontrar e solicitar execuções de atividades por meio do cuidador. A intervenção baseia-se no modelo do trabalho de [Thorpe et al. 2019], em que neste caso específico, ao identificar que o paciente está perdido ou está muito longe da localização *GPS* do lar de idosos onde reside, um alerta é enviado para o cuidador apresentando possível perigo à saúde e segurança do paciente. O DCARE tem como objetivo enviar também um alerta para o cuidador em caso de possível perigo à segurança e saúde do paciente, porém o diferencial é que este alerta é gerado observando não só os dados de localização *GPS* mas também de sinais vitais.

4.2. Entidades de Contexto

Arquiteturas sensíveis ao contexto que usam não apenas contextos presentes, mas também contextos sobre o passado, precisam armazenar contextos observados para uso posterior [Filippetto et al. 2021]. Esses trabalhos geralmente possuem uma representação de domínio bem definida por meio de uma ontologia. A ontologia representa um conhecimento sobre baixo e alto nível de contextos, apresentando as entidades envolvidas, bem como sua relação de forma semântica [Sigg 2008a].

A composição das Entidades de Contexto do modelo DCARE aborda a utilização dos conceitos do Sistema Nervoso Autônomo (SNA), que controla os processos fisiológicos do corpo humano (por exemplo, sistemas cardiovascular, digestivo e respiratório) e intervém nas respostas involuntárias a estímulos externos [Cacioppo et al. 2007] [Kreibig 2010]. Recentemente, o alcance das emoções [Choi et al. 2017] [Shu et al. 2018], em relação a esse aspecto tem recebido atenção. Medidas fisiológicas têm sido utilizadas para avaliar a atividade autônoma do paciente. As medidas mais comuns encontradas na literatura da psicofisiologia são a atividade cardiovascular, a condutividade elétrica da pele, a respiração e a atividade muscular [Kreibig 2010] [Smets et al. 2019]. A Variabilidade da Frequência Cardíaca (VFC), extraída da análise cardiovascular (ECG - eletrocardiograma), é um indicador fisiológico não invasivo das funções do SNA que examina as flutuações na Frequência Cardíaca (FC). Essa flutuação é representada pela diferença de tempo entre dois batimentos consecutivos, também conhecidos como intervalos R-R. VFC é um marcador confiável da atividade do SNA [Castaldo et al. 2015][Choi et al. 2017] e um marcador relevante de bem-estar psicológico [Chalmers et al. 2014]. Por essas razões, DCARE utiliza VFC como uma medida chave no modelo.

A Figura 3 mostra a modelagem de dados de contexto utilizada pelo DCARE, tanto na aquisição quanto no processamento de dados. A ontologia do DCARE é utilizada para obtenção e classificação das informações de contexto do projeto. Neste sentido, a ontologia desenvolvida foi utilizada para a modelagem do domínio e para a representação do modelo de dados. A entidade *Cuidador* representa a pessoa responsável por prestar auxílio e realizar o monitoramento do paciente. A entidade *Paciente* possui a identificação do paciente e o tipo de demência que o mesmo possui. As entidades de referência e identificação do histórico de contexto são *Identidade*, que garante a identificação única pelo usuário, e *DataHora*, identifica o instante no decorrer do tempo. As entidades que compõem o modelo para que seja feito o processamento dos dados de comportamento dos pacientes são: *Atividade*, *FrequenciaCardiaca* e *LocalizacaoSemantica*. A entidade *FrequenciaCardiaca* é a representação da variação de sinais VFC, obtidos por meio do monitoramento das batidas do coração. A entidade *LocalizacaoSemantica* representa a localização representativa de onde o paciente está no momento relacionando-a com a sua geolocalização. A entidade *Atividade* representa o tipo de movimentação que o paciente está realizando, de acordo com a *FrequenciaCardiaca* e *LocalizacaoSemantica*, e pode ilustrar quatro tipos possíveis de movimentos, que são: *Parado*, *Caminhada*, *Corrida* e *EmVeiculo*. Além disso, a *Atividade* também desempenha um papel essencial na forma como o usuário se relaciona com o meio ambiente.

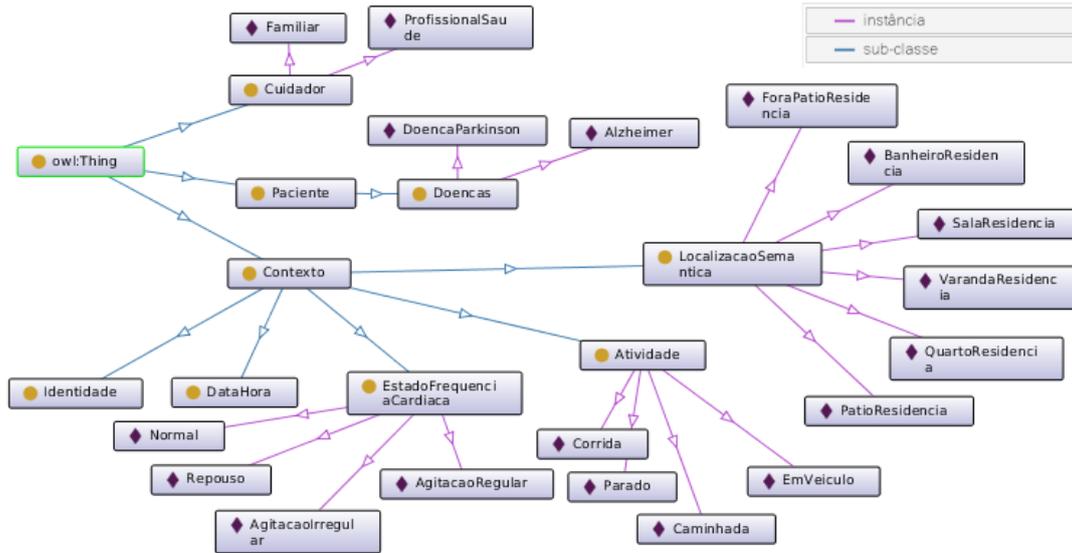


Figure 3. Ontologia de Contextos para Alzheimer.

4.3. Predição de Contextos

O DCARE prevê o acompanhamento de pessoas com a doença de Alzheimer durante o cotidiano, acompanhando o usuário e coletando informações diárias sobre localização via *GPS* e sinais vitais do paciente, que podem ajudar em cuidados mais adequados e personalizados para os usuários, disponibilizando um maior suporte para os cuidadores nas tarefas de preservar a saúde e segurança do paciente. O modelo computacional DCARE tem como base de ferramenta para análise e processamento de contextos a utilização dos conceitos de Históricos de Contextos e Predições de Contextos, onde é possível realizar o registro de dados de acordo com seleção de informações relevantes de contexto.

O funcionamento do DCARE é regido por duas etapas, onde cada uma delas executa um conjunto específico de tarefas para o funcionamento dos módulos. As etapas são divididas em: (1) Aquisição de dados, processamento/identificação de contextos, e geração de Históricos de Contextos; e (2) Identificação de comportamento, predições de contexto e geração de alerta. A execução inicia assim que os dados são disponibilizados pela aplicação externa que coleta os dados. A primeira etapa realiza a obtenção dos dados dos pacientes e associa à ontologia do modelo, em seguida, armazena os dados na base de dados, ou seja, resultando na geração dos Históricos de Contextos. A segunda etapa, no primeiro estágio, executada no módulo de Identificação de Comportamento, realiza a identificação de comportamentos baseados no conceito *BPSD*, ou seja, realizando o processamento de identificação dos dados, de acordo com os cenários abordados e validados na Seção 5. Ainda na segunda etapa, no segundo estágio, executada no módulo de Identificação de Comportamento, é realizada a geração de predições de contextos de comportamentos do paciente e encaminha os dados para a fila de mensagens. O módulo de Predições de Contextos é executado utilizando como base a biblioteca *scikit-learn*², que

²<https://scikit-learn.org>

disponibiliza funções que realizam a análise de dados com base no conceito de Aprendizado de Máquina, e utiliza como base para realização do processamento os dados armazenados de Históricos de Contextos. Finalizando o fluxo de execução, a aplicação consumidora tem acesso aos dados finais gerados pelo modelo a partir da fila de mensagens.

5. Aspectos de Implementação

A implementação de um protótipo seguindo as especificações do modelo foi realizada utilizando a linguagem de programação *Python*, a fim de permitir sua avaliação. Para constituição da arquitetura do projeto foi utilizado um banco de dados SQL, e como *gateway* de fila de mensagens a ferramenta *RabbitMQ*³.

A técnica de entrevista foi utilizada para realização da coleta de informações que foram utilizadas no desenvolvimento dos cenários do modelo para identificar os diferentes contextos que compõem o cotidiano dos pacientes com Alzheimer e seus cuidadores. Esta técnica foi escolhida levando em consideração a grande abrangência de possíveis situações em que o paciente possa se encontrar e buscando enriquecer o trabalho com cenários que usualmente não são destacados na literatura acadêmica. De acordo com [Ribeiro 2008], recorre-se à entrevista sempre que se tem necessidade de obter dados que não podem ser encontrados em registros e fontes documentais, podendo estes serem fornecidos por determinadas pessoas. Ainda segundo [Ribeiro 2008], a entrevista é a técnica mais pertinente quando o pesquisador deseja obter informações a respeito do seu objeto, que permitam conhecer sobre atitudes, sentimentos e valores subjacentes ao comportamento, o que significa que se pode ir além das descrições das ações, incorporando novas fontes para a interpretação dos resultados pelos próprios entrevistados. Com o intuito de detectar a visão de cuidadores e profissionais da saúde sobre sua rotina diária em ambientes diferenciados, foram desenvolvidos alguns cenários pertinentes baseados na literatura acadêmica, onde os entrevistados foram convidados a comentar e contribuir com informações sobre o cenário além de propor novos cenários baseados no objetivo do trabalho. Os cenários desenvolvidos com base na literatura que compõem os itens de pesquisa das entrevistas estão descritos na Tabela 2.

A Tabela 4 mostra que a construção dos cenários que foram utilizados no desenvolvimento do modelo foi realizada em entrevista com cinco voluntários. As entrevistas foram realizadas via vídeo chamada por um aplicativo para *smartphone*, e foram gravadas e salvas para posterior análise, de acordo com o consentimento dos entrevistados. O perfil dos entrevistados é diverso, e é composto por cuidadores que possuem experiência entre 1 e 28 anos atuando no cuidado de pessoas com a doença de Alzheimer. No que diz respeito à ocupação, 60% dos entrevistados tem como profissão a área da saúde, cuidador de idosos e/ou cuidador de pacientes com a doença de Alzheimer, sendo os outros 40% dos entrevistados familiares dos pacientes.

Por meio das entrevistas realizadas, foi possível construir a síntese dos dados e identificar comportamentos em comum realizados por pacientes com doença de Alzheimer que podem ser identificados como perigosos à saúde e segurança do paciente.

³<https://www.rabbitmq.com/>

Table 2. Cenários desenvolvidos com base na literatura.

| ID | Descrição | Frequência Cardíaca | Atividade | Localização Semântica | Duração | Horário início / finalização | Necessário realizar geração de alerta ao cuidador |
|-----|--|-------------------------------------|--------------------------------|--|----------|---------------------------------|---|
| CE1 | O paciente está passando por um ataque de disfunção psicológica (sintomas BPSD - behavioral and psychological symptoms of dementia) | AgitaçãoRegular / AgitaçãoIrregular | Parado | BanheiroResidencia / QuartoResidencia / SalaResidencia / CozinhaResidencia / VarandaResidencia / PatioResidencia / ForaPatioResidencia | 1 minuto | entre 00:00 horas e 23:59 horas | Sim |
| CE2 | O paciente está em fuga sem acompanhamento (sintomas BPSD - behavioral and psychological symptoms of dementia) | Normal / AgitaçãoRegular | Caminhada / Corrida | VarandaResidencia / PatioResidencia / ForaPatioResidencia | 1 minuto | entre 00:00 horas e 23:59 horas | Sim |
| CE3 | O paciente está passando por um ataque de disfunção psicológica relacionados a ambientes desconhecidos (sintomas BPSD - behavioral and psychological symptoms of dementia) | AgitaçãoRegular / AgitaçãoIrregular | Parado / Caminhada / EmVeículo | PatioResidencia / ForaPatioResidencia | 1 minuto | entre 00:00 horas e 23:59 horas | Sim |
| CE4 | O paciente está passando por um problema de saúde respiratório/cardíaco | AgitaçãoIrregular | Parado | BanheiroResidencia / QuartoResidencia / SalaResidencia / CozinhaResidencia / VarandaResidencia / PatioResidencia / ForaPatioResidencia | 1 minuto | entre 00:00 horas e 23:59 horas | Sim |
| CE5 | O paciente está dormindo | Repouso | Parado | QuartoResidencia / SalaResidencia | 1 minuto | entre 00:00 horas e 23:59 horas | Não |
| CE6 | O paciente está em um cenário normal | Normal | Parado / Caminhada / EmVeículo | BanheiroResidencia / QuartoResidencia / SalaResidencia / CozinhaResidencia / VarandaResidencia / PatioResidencia / ForaPatioResidencia | 1 minuto | entre 08:01 horas e 22:59 horas | Não |

Como resultado da entrevistas, os cenários identificados anteriormente com base na literatura foram aprovados, e quatro cenários a mais foram adicionados para validação de acordo com a Tabela 3. Resultando em dez cenários a serem utilizados pelo modelo.

6. Aspectos de Avaliação

A avaliação foi realizada utilizando o teste de aceitabilidade baseado nos dados coletados através das entrevistas descritas na Seção 5. Os registros que representam instâncias dos cenários utilizados nos testes foram gerados com a ferramenta *DCARE Dataset Simulator*. A aplicação foi construída utilizando como base a linguagem de programação *Python*. O simulador leva em consideração cada um dos itens especificados na Subseção 4.2. Cada simulação é gerada de acordo com a escolha randômica dos itens da estrutura. Durante

Table 3. Cenários desenvolvidos com base nas entrevistas.

| ID | Descrição | Frequência Cardíaca | Atividade | Localização Semântica | Duração | Horário início / finalização | Necessário realizar geração de alerta ao cuidador |
|-----|--|--|--|--|------------------------|---|---|
| CE1 | O paciente está passando por uma convulsão (sintomas BPSD - behavioral and psychological symptoms of dementia) | AgitacaoIrregular | Parado / Caminhada / Corrida / EmVeiculo | BanheiroResidencia / QuartoResidencia / SalaResidencia / CozinhaResidencia / VarandaResidencia / PatioResidencia / ForaPatioResidencia | 1 minuto e 30 segundos | entre 00:00 horas e 23:59 horas | Sim |
| CE2 | O paciente está em um cenário de queda ao tentar realizar atividades de banho ou higiene sozinho (sintomas BPSD - behavioral and psychological symptoms of dementia) | AgitacaoRegular / AgitacaoIrregular | Parado | BanheiroResidencia | 1 minuto | entre 00:00 horas e 23:59 horas | Sim |
| CE3 | O paciente está em um cenário em que acorda durante a madrugada e está desacompanhado, noção de tempo e horas inconsistentes (sintomas BPSD - behavioral and psychological symptoms of dementia) | Normal / AgitacaoRegular / AgitacaoIrregular | Parado / Caminhada / Corrida | BanheiroResidencia / QuartoResidencia / SalaResidencia / CozinhaResidencia / VarandaResidencia / PatioResidencia | 1 minuto | horário de descanso noturno, entre 23:00 horas e 8:00 horas | Sim |
| CE4 | O paciente está em um cenário em que está com algum tipo de infecção no corpo porém não demonstra febre (sintomas BPSD - behavioral and psychological symptoms of dementia) | AgitacaoRegular / AgitacaoIrregular | Parado / Caminhada / Corrida / EmVeiculo | BanheiroResidencia / QuartoResidencia / SalaResidencia / CozinhaResidencia / VarandaResidencia / PatioResidencia / ForaPatioResidencia | 2 horas | entre 00:00 horas e 23:59 horas | Sim |

as simulações todos os itens são substituídos por um modelo de dicionário, onde cada elemento recebe um enumerador como identificador.

A construção do simulador foi realizada de acordo com os dados enumerados identificados com um modelo de dicionário, apresentados na Tabela 5. Para geração do *dataset*, os cenários identificados na Seção 5, foram construídos com a estrutura:

- (1) *id.cenario*: identificação enumerada do cenário;
- (2) *estado_frequencia_cardiaca*: estado da frequência cardíaca na duração especificada no contexto;
- (3) *atividade*: comportamento do paciente especificado na duração do contexto;
- (4) *localizacao_semantica*: localização do paciente significativa de acordo com o

Table 4. Perfis dos entrevistados.

| ID Cenário | Perfil Profissional e Acadêmico | Anos de atuação |
|--------------|--|-----------------|
| CE1 | Cuidadora Geriátrica; Curso de Cuidador de Idosos | 17 |
| CE1 | Técnica de Enfermagem; Curso Técnico de Enfermagem | 1 |
| CE2 e CE4 | Cuidadora de Pacientes com Doença de Alzheimer; Curso Técnico de Enfermagem | 28 |
| CE3 | Familiar | 2 |
| CE3 | Familiar | 12 |

espaço de vivência diário;

- (5) duracao: tempo de duração do contexto (em minutos);
- (6) horario_inicio_final: data de início e final do contexto;
- (7) necessario_alerta_cuidador: se há necessidade de enviar um alerta de perigo ao cuidador.

Table 5. Dados da estrutura de dicionário do DCARE Dataset Simulator.

| Descrição do item | Estados de cada item |
|----------------------------|--|
| Estado Frequência Cardíaca | repouso (1), normal (2), agitacaoRegular (3), agitacaoIrregular (4) |
| Atividade | parado (1), caminhada (2), corrida (3), emVeiculo (4) |
| Localização Semântica | banheiro (1), quarto (2), sala (3), cozinha (4), varanda (5), patio (6), foraPatio (7) |
| Necessário Alerta Cuidador | false (0), true (1) |

Os cenários utilizados na construção dos *dataset* foram construídos de acordo com a Tabela 6, e gerados no formato de arquivo *csv*.

Table 6. Cenários utilizados para geração de datasets do DCARE Dataset Simulator.

| ID | Descrição do cenário | (1) | (2) | (3) | (4) | (5) | (6) | (7) |
|------|--|-----|---------|------------|---------------------|-----|---------------------------|-----|
| CN1 | Ataque de Disfunção Psicológica | 1 | 3, 4 | 1 | 1, 2, 3, 4, 5, 6, 7 | 1 | | 1 |
| CN2 | Fuga sem Acompanhamento | 2 | 2, 3 | 2, 3 | 5, 6, 7 | 1 | | 1 |
| CN3 | Disfunção Psicológica em ambiente desconhecido | 3 | 3, 4 | 1, 2, 4 | 7, 8 | 1 | | 1 |
| CN4 | Problema Saúde Respiratório | 4 | 4 | 1 | 1, 2, 3, 4, 5, 6, 7 | 1 | | 1 |
| CN5 | Dormindo | 5 | 1 | 1 | 2, 3 | 1 | | 0 |
| CN6 | Cenário Normal | 6 | 2 | 1, 2, 4 | 1, 2, 3, 4, 5, 6, 7 | 1 | "08:01:00", "22:59:59" | 0 |
| CN7 | Ataque Saúde Convulsão | 7 | 4 | 1, 2, 3, 4 | 1, 2, 3, 4, 5, 6, 7 | 2 | | 1 |
| CN8 | Queda em atividades de banho/higiene | 8 | 3, 4 | 1 | 1 | 1 | | 1 |
| CN9 | Acordado durante madrugada desacompanhado | 9 | 2, 3, 4 | 1, 2, 3 | 1, 2, 3, 4, 5, 6 | 1 | "23:00:00", "08:00:59" | 1 |
| CN10 | Infeção porém sem febre | 10 | 3, 4 | 1, 2, 3, 4 | 1, 2, 3, 4, 5, 6, 7 | 120 | | 1 |

6.1. Resultados

Com a utilização da biblioteca *scikit-learn*² para a linguagem Python, implementou-se o algoritmo de aprendizado de máquina supervisionado de classificação *Random Forest*, aonde foi possível realizar o treinamento do modelo e subsequente teste das amostras de contexto geradas. A realização dos testes foi efetuada com um *dataset* com 1026 amostras geradas pelo *DCARE Dataset Simulator*⁴. As amostras foram geradas de forma aleatória e com as instâncias já normalizadas pelo simulador para todos os atributos. O simulador foi programado para ser imparcial nas gerações dos contextos, ignorando-se questões de balanceamento das amostras entre eventos de risco e não-risco.

Utilizando-se o método de *train-test split*, com segmentação em 10 *splits* utilizando-se a biblioteca *scikit-learn*, onde baseando-se no modelo previamente treinado foi possível realizar a execução das chamadas para geração das predições de contextos. Adotou-se a proporção de 80/20 para a segmentação do *dataset* entre treinamento e teste.

Na Tabela 7 é possível visualizar a média de acurácia do modelo em relação a predições de contexto de acordo com diferentes quantidades de amostras. Com a menor quantidade de amostras utilizada (100) foi possível identificar a menor média de acurácia com 97,3%, e com a maior quantidade de amostras (1026) é possível identificar que a média de acurácia é elevada, chegando a 97,5%.

Table 7. Testes de acurácia do modelo DCARE.

| Quantidade de amostras | Média de acurácia |
|------------------------|-------------------|
| 100 | 97,3% |
| 200 | 97,4% |
| 400 | 97,5% |
| 600 | 97,5% |
| 1026 | 97,5% |

A partir dos diferentes testes realizados, alterando a quantidade de amostras utilizadas, foi possível identificar que a média geral de acurácia do modelo é 97,44%. Com base nas simulações realizadas sobre os dados, pode-se concluir que houve eficácia do modelo, no intuito de identificar cenários perigosos à saúde ou segurança do paciente de forma preditiva.

Conforme visualiza-se na Figura 4, o algoritmo de *machine learning Random Forest* treinado considerando-se o *dataset* gerado pelo *DCARE Dataset Simulator* atingiu uma performance média geral de 97,47%.

Todavia, analisando-se individualmente as métricas de sensibilidade, especificidade, precisão, acurácia e *FI-score*, conforme visualiza-se na Tabela 8, observam-se algumas particularidades relevantes do modelo de aprendizado de máquina avaliado.

A especificidade do modelo foi de praticamente 99%, o que denota a alta capacidade de detecção de casos efetivamente não emergenciais, que não devem ser notificados. Por outro lado, a métrica de sensibilidade alcançou praticamente 60% e a precisão mais de 66%. Neste caso, devido aos 11 casos de falso positivos o modelo poderia indicar a

⁴<https://github.com/savannadenega/dcure-context-prediction/>

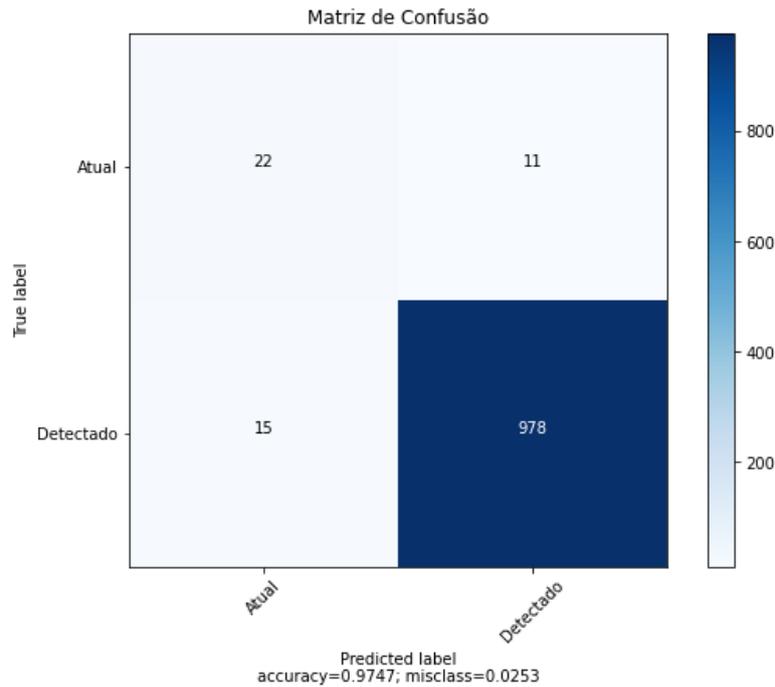


Figure 4. Matriz de Confusão.

geração de alertas para situações não críticas. Do ponto de vista do cuidador estes eventos poderiam ser facilmente validados e ignorados. Entretanto, dados os 15 casos de falso negativos medidos, o modelo deixaria de recomendar a intervenção para pacientes que efetivamente necessitariam de acompanhamento especial. Experimentos adicionais envolvendo outros algoritmos de aprendizado de máquina e *datasets* maiores com distribuição balanceada e validação cruzada deverão ser implementados visando aprimoramento do modelo quanto à sensibilidade e precisão.

Table 8. Métricas de desempenho do algoritmo de *machine learning* Random Forest aplicado ao modelo DCARE.

| Sensibilidade | Especificidade | Precisão | Acurácia | <i>F1-score</i> |
|---------------|----------------|----------|----------|-----------------|
| 59,46 | 98,89 | 66,67 | 97,47 | 62,86 |

7. Conclusão

Este artigo consiste em uma versão estendida do trabalho publicado no Simpósio Brasileiro de Sistemas de Informação (SBSI) em 2021. O texto apresentou de forma detalhada o modelo para acompanhamento de pessoas com a doença de Alzheimer, DCARE, em um cenário do dia a dia de atendimento pelos seus cuidadores. Baseado nos estudos dos trabalhos relacionados ao tema, notou-se a oportunidade de desenvolvimento de um modelo para oferecer o acompanhamento de pacientes com a doença de Alzheimer, possibilitando cuidados individuais a cada usuário, em que as análises realizadas resultam na predição e/ou alerta de possíveis perigos à saúde e segurança do paciente. Os dados

coletados com base no conceito Históricos de Contextos são analisados e processados, resultando na compreensão de comportamentos ou predição de comportamentos futuros do paciente, gerando um alerta ao cuidador caso demonstre algum tipo de perigo à saúde ou segurança do usuário, sendo estes os grandes diferenciais em relação ao estado da arte atual.

A construção dos cenários que foram utilizados no desenvolvimento do modelo foi realizada nas entrevistas realizadas com cinco voluntários, com perfis de profissional da saúde e familiares. A massa de dados para realização dos testes foi gerada pelo *DCARE Dataset Simulator*. Os resultados dos testes baseados nas predições de contextos mostraram que o modelo desenvolvido atendeu o objetivo do projeto, atingindo 97,44% de taxa geral de acurácia de predição de cenários. Com base nas simulações realizadas sobre os dados, pode-se concluir que houve eficácia do modelo, no intuito de identificar preditivamente cenários de perigo à saúde ou segurança do paciente, de forma preditiva.

A principal contribuição científica deste trabalho é a especificação de um modelo para acompanhamento de pessoas com a doença de Alzheimer durante o dia a dia, acarretando na ajuda aos seus cuidadores, interagindo com recursos tecnológicos, promovendo o acesso a uma ferramenta para cuidados para a saúde e segurança dos pacientes, além de contribuir com o desenvolvimento de um simulador de *datasets* com cenários atividades diárias de pacientes com a doença de Alzheimer.

Como contribuição social pode-se salientar o desenvolvimento de um novo recurso para utilização dentro da área de cuidados a saúde mental, colaborando com o desenvolvimento de uma aplicação que pode ser largamente utilizada pelos cuidadores.

Baseado nos estudos desse trabalho, surgem novas possibilidades para a continuidade de trabalhos futuros. A utilização do modelo para pessoas com outros tipos de doenças neurodegenerativas progressivas é muito promissora, especialmente pelo recurso de acompanhamento diário, gerando informações importantes para os cuidadores sobre a saúde individual de cada usuário.

Além disso, projetam-se experimentos complementares utilizando-se dados coletados de *wearables* portados por usuários reais. Este trabalho limitou-se ao uso de dados sintéticos provisionados pelo *DCARE Dataset Simulator* tendo em vista que as limitações de distanciamento social impostas pela pandemia do COVID-19 restringiram os experimentos com pessoas com comorbidades. Entretanto, o *dataset* utilizado seguiu o padrão científico de geração de cenários baseados no estado da arte e validados por 5 especialistas na área do estudo. Os contextos experimentados cobrem a maioria dos estados críticos que devem ser monitorados para pessoas com Alzheimer. Neste sentido, destaca-se a importância do simulador desenvolvido, sendo capaz de gerar contextos para cenários idênticos aos reais de modo seguro, possibilitando a realização de avaliações do modelo sem a exposição das pessoas a riscos.

Agradecimentos

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado do Rio Grande do Sul (FAPERGS), à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, ao Conselho Nacional de Desenvolvimento

Científico e Tecnológico (CNPq) e à Universidade do Vale do Rio dos Sinos (Unisinos) pelo apoio ao desenvolvimento desse trabalho. Os autores reconhecem especialmente o apoio do Programa de Pós-Graduação em Computação Aplicada (PPGCA) e do Laboratório de Computação Móvel (Mobilab) da Unisinos.

References

- Amato, F., Crovari, P., Masciadri, A., Bianchi, S., Pasquarelli, M. G. G., Toldo, M., Comai, S., Imtiaz, A., and Yuyar, E. (2018). Clone: A promising system for the remote monitoring of Alzheimer's patients an experimentation with a wearable device in a village for Alzheimer's care. *ACM International Conference Proceeding Series*, June:255–260.
- Aranda, J. A. S., Bavaresco, R., Carvalho, J. V., Yamin, A. C., Tavares, M. T., and Barbosa, J. L. V. (2021). A computational model for adaptive recording of vital signs through context histories. *Journal of Ambient Intelligence and Humanized Computing*, 1:1–15.
- Association, A. (2022). What is alzheimer's disease? <https://www.alz.org/alzheimers-dementia/what-is-alzheimers>.
- AZ, A. D. I. (2015). World alzheimer report 2015: The global impact of dementia. <https://www.alz.co.uk/research/world-report-2015>.
- AZ, A. D. I. (2022). About dementia. <https://www.alz.co.uk/about-dementia>.
- Barbosa, J. L. V. (2015). Ubiquitous computing: Applications and research opportunities. In *2015 IEEE International Conference on Computational Intelligence and Computing Research (ICIC)*, pages 1–8.
- Brodaty, H., Connors, M., Xu, J., Woodward, M., Ames, D., and PRIME study group (2014). Predictors of institutionalization in dementia: a three year longitudinal study. *Journal of Alzheimer's disease : JAD*, 40(1):221–226.
- Burleson, W., Lozano, C., Ravishankar, V., Lee, J., and Mahoney, D. (2018). An assistive technology system that provides personalized dressing support for people living with dementia: Capability study. *Journal of Medical Internet Research*, 20(5):1–20.
- Cacioppo, J. T., Tassinary, L. G., and Berntson, G., editors (2007). *Handbook of Psychophysiology*. Cambridge University Press, Trinity, Cambridge, UK, 3 edition.
- Castaldo, R., Melillo, P., Bracale, U., Caserta, M., Triassi, M., and Pecchia, L. (2015). Acute mental stress assessment via short term hrv analysis in healthy adults: A systematic review with meta-analysis. *Biomedical Signal Processing and Control*, 18:370–377.
- Chalmers, J. A., Quintana, D. S., Abbott, M. J.-A., and Kemp, A. H. (2014). Anxiety disorders are associated with reduced heart rate variability: A meta-analysis. *Frontiers in Psychiatry*, 5:80.
- Choi, K.-H., Kim, J., Kwon, O. S., Kim, M. J., Ryu, Y. H., and Park, J.-E. (2017). Is heart rate variability (hrv) an adequate tool for evaluating human emotions? – a focus on the

- use of the international affective picture system (iaps). *Psychiatry Research*, 251:192–196.
- Cohen-Mansfield, J. (2008). Agitated behavior in persons with dementia: the relationship between type of behavior, its frequency, and its disruptiveness. *Journal of psychiatric research*, 43(1):64–69.
- Cohen-Mansfield, J., Thein, K., Marx, M. S., Dakheel-Ali, M., and Freedman, L. (2012). Efficacy of nonpharmacologic interventions for agitation in advanced dementia: a randomized, placebo-controlled trial. *The Journal of clinical psychiatry*, 73(9):1255—1261.
- da Rosa, J. H., Barbosa, J. L., and Ribeiro, G. D. (2016). Oracon: An adaptive model for context prediction. *Expert Systems with Applications*, 45:56–70.
- da Silva, D. L. (2009). Ontologias e unified modeling language: uma abordagem para representação de domínios de conhecimento. <https://brapci.inf.br/index.php/res/v/7006>.
- de Geografia e Estatística IBGE, I. B. (2022). Síntese de indicadores sociais uma análise das condições de vida da população brasileira (2012). <https://biblioteca.ibge.gov.br/visualizacao/livros/liv66777.pdf>.
- Dey, A. K., Abowd, G. D., and Salber, D. (2001). A conceptual framework and a toolkit for supporting the rapid prototyping of context-aware applications. *Hum.-Comput. Interact.*, 16(2):97–166.
- Driver, C. and Clarke, S. (2004). Context-aware trails [mobile computing]. *Computer*, 37(08):97–98.
- Driver, C. and Clarke, S. (2008). An application framework for mobile, context-aware trails. *Pervasive and Mobile Computing*, 4:719–736.
- Ferrah, N., Murphy, B. J., Ibrahim, J. E., Bugeja, L. C., Winbolt, M., LoGiudice, D., Flicker, L., and Ranson, D. L. (2015). Resident-to-resident physical aggression leading to injury in nursing homes: a systematic review. *Age and Ageing*, 44(3):356–364.
- Filippetto, A. S., Lima, R., and Barbosa, J. L. V. (2021). A risk prediction model for software project management based on similarity analysis of context histories. *Information and Software Technology*, 131:106497.
- Fowler, C. N., Kott, K., Wicks, M. N., and Rutledge, C. (2016). Self-efficacy and sleep among caregivers of older adults with dementia: Effect of an interprofessional virtual healthcare neighborhood. *Journal of Gerontological Nursing*, 42(11):39–47.
- Keet, M. (2018). An introduction to ontology engineering. <https://open.umn.edu/opentextbooks/textbooks/590>.
- Khoo, S. A., Chen, T. Y., Ang, Y. H., and Yap, P. (2013). The impact of neuropsychiatric symptoms on caregiver distress and quality of life in persons with dementia in an asian tertiary hospital memory clinic. *International Psychogeriatrics*, 25(12):1991–1999.

- Kreibig, S. D. (2010). Autonomic nervous system activity in emotion: A review. *Biological Psychology*, 84(3):394 – 421. The biopsychology of emotion: Current theoretical and empirical perspectives.
- Lai Kwan, C., Mahdid, Y., Motta Ochoa, R., Lee, K., Park, M., and Blain-Moraes, S. (2019). Wearable technology for detecting significant moments in individuals with dementia. *BioMed Research International*, 2019:2314–6133.
- Machado, S. D. and Barbosa, J. L. V. (2020). Technologies applied in the care of patients with alzheimer’s disease: A systematic review. In *Proceedings of the Brazilian Symposium on Multimedia and the Web, WebMedia ’20*, page 29–32, New York, NY, USA. Association for Computing Machinery.
- Machado, S. D., Barbosa, J. L. V., Tavares, J. a. d. R., and Martins, M. G. (2021). Dcare: Um modelo computacional para acompanhamento de pessoas com doença de alzheimer baseado na análise de históricos de contextos: Dcare: A computational model for monitoring people with alzheimer’s disease based on context histories analysis. In *XVII Brazilian Symposium on Information Systems, SBSI 2021*, New York, NY, USA. Association for Computing Machinery.
- Martini, B. G., Helfer, G. A., Barbosa, J. L. V., Modolo, R. C. E., Silva, M. R., Figueiredo, R. M., Mendes, A. S., Silva, L. A., and Leithardt, V. R. Q. (2021). Indoorplant: A model for intelligent services in indoor agriculture based on context histories. *Sensors*, 21:1631.
- Murman, D., Chen, Q., Powell, M., Kuo, S., Bradley, C., and Colenda, C. (2002a). The incremental direct costs associated with behavioral symptoms in ad. *Neurology*, 59(11):1721–1729.
- Murman, D., Chen, Q., Powell, M., Kuo, S., Bradley, C., and Colenda, C. (2002b). The incremental direct costs associated with behavioral symptoms in ad. *Neurology*, 59(11):1721–1729.
- National Alliance for Caregiving, U. H. (2011). e-connected family caregiver: Bringing caregiving into the 21st century. http://www.caregiving.org/data/FINAL_eConnected_Family_Caregiver_Study_Jan%202011.pdf.
- Nesbitt, C., Gupta, A., Jain, S., Maly, K., and Okhravi, H. R. (2018a). Reliability of wearable sensors to detect agitation in patients with dementia: A pilot study. In *Proceedings of the 2018 10th International Conference on Bioinformatics and Biomedical Technology, ICBBT ’18*, page 73–77, New York, NY, USA. Association for Computing Machinery.
- Nesbitt, C., Gupta, A., Jain, S., Maly, K., and Okhravi, H. R. (2018b). Reliability of wearable sensors to detect agitation in patients with dementia: A pilot study. In *Proceedings of the 2018 10th International Conference on Bioinformatics and Biomedical Technology, ICBBT ’18*, page 73–77, New York, NY, USA. Association for Computing Machinery.
- OPAS, O. P. A. d. S. (2022). Folha informativa 2018: 10 principais causas de morte no mundo. <https://www.paho.org/bra/index.php?option=>

com_content&view=article&id=5638:10-principais-causas-de-morte-no-mundo&Itemid=0.

- Pillemer, K., Chen, E. K., Van Haitsma, K. S., Teresi, J., Ramirez, M., Silver, S., Sukha, G., and Lachs, M. S. (2011). Resident-to-Resident Aggression in Nursing Homes: Results from a Qualitative Event Reconstruction Study. *The Gerontologist*, 52(1):24–33.
- Protégé (2022). A free, open-source ontology editor and framework for building intelligent systems. <https://protege.stanford.edu/>.
- Ribeiro, E. A. (2008). A perspectiva da entrevista na investigação qualitativa. In *A perspectiva da entrevista na investigação qualitativa*, volume 4, pages 129–148.
- SAP (2007). Standardized technical architecture e modeling - conceptual and design level. http://www.fmc-modeling.org/download/fmc-and-tam/SAP-TAM_Standard.pdf. Disponível em: <http://www.fmc-modeling.org/download/fmc-and-tam/SAP-TAM/Standard.pdf>.
- Shu, L., Xie, J., Yang, M., Li, Z., Li, Z., Liao, D., Xu, X., and Yang, X. (2018). A review of emotion recognition using physiological signals. *Sensors*, 18(7):2074.
- Sigg, S. (2008a). *Development a novel context prediction algorithm and analysis of context prediction schemes*. Kassel University Press, Kassel, Alemanha.
- Sigg, S. (2008b). Development of a novel context prediction algorithm and analysis of context prediction schemes.
- Sigg, S., Haseloff, S., and David, K. (2011). An alignment approach for context prediction tasks in ubicomp environments. *Pervasive Computing, IEEE*, 9:90 – 97.
- Silva, J., Rosa, J., Barbosa, J., Barbosa, D., and Palazzo, L. (2010). Content distribution in trail-aware environments. *J. Braz. Comp. Soc.*, 16:163–176.
- Smets, E., De Raedt, W., and Van Hoof, C. (2019). Into the wild: The challenges of physiological stress detection in laboratory and ambulatory settings. *IEEE Journal of Biomedical and Health Informatics*, 23(2):463–473.
- Smith, A. (2008). *Who Controls the Past Controls the Future - Life Annotation in Principle and Practice*. PhD thesis, University of Southampton.
- Tan, L. L., Wong, H. B., and Allen, H. (2005). The impact of neuropsychiatric symptoms of dementia on distress in family and professional caregivers in Singapore.
- Thorpe, J. R., Forchhammer, B. H., and Maier, A. M. (2019). Development of a sensor-based behavioral monitoring solution to support dementia care. *Journal of Medical Internet Research*, 21(6):1–14.
- Vugt, M. E. d., Stevens, F., Aalten, P., Lousberg, R., Jaspers, N., and Verhey, F. R. J. (2005). A prospective study of the effects of behavioral symptoms on the institutionalization of patients with dementia. *International Psychogeriatrics*, 17(4):577–589.
- Wan, L., Müller, C., Randall, D., and Wulf, V. (2016). Design of a gps monitoring system for dementia care and its challenges in academia-industry project. *ACM Trans. Comput.-Hum. Interact.*, 23(5).

WHO, W. H. O. (2022a). Dementia: 2019 statistical update. <https://www.who.int/news-room/fact-sheets/detail/dementia>.

WHO, W. H. O. (2022b). Who global action plan on the public health response to dementia 2017–2025. <http://www.who.int/nmh/publications/ncd-action-plan/en/>.