

# Identificando Comportamentos de Risco para Doenças Crônicas: Uma abordagem baseada em ontologia

## Identifying Chronic Disease Risk Behaviors: An ontology-based approach

Lucas Pfeiffer Salomão Dias <sup>1</sup>, Henrique Damasceno Vianna <sup>1</sup>, Weslle Heckler <sup>1</sup>, Jorge Luis Victória Barbosa <sup>1</sup>

<sup>1</sup>Programa de Pós-graduação em Computação Aplicada (PPGCA)  
Universidade do Vale do Rio dos Sinos (UNISINOS)  
São Leopoldo, Rio Grande do Sul – Brasil

lucaspfds@gmail.com, hdvianna@gmail.com,  
weslleheckler@edu.unisinos.br, jbarbosa@unisinos.br

**Abstract.** *Chronic diseases are among the leading causes of death worldwide. Risk factors related to chronic diseases are correlated with people's lifestyles, and early changes can prevent many chronic disease deaths. This article proposes an ontology called B-Track Onto to classify behaviors that attenuate or worsen the risk factors associated with chronic diseases. The MIMIC-III dataset was used as the base to import 21 patients from the clinical samples. B-Track Onto inferred all imported patients and categorized them in the expected classes. Besides, this work executed SPARQL queries to answer the competence questions, which returned the expected results for each question. Furthermore, there was an evaluation of the ontology with 10 patients over 4 weeks, showing the ontology's ability to infer behaviors related to risk factors for chronic diseases during the patients' daily lives. This evaluation allowed the inference of patients' preventive and non-preventive habits related to chronic diseases. B-Track Onto is an ontology to correlate human behavior and risk factors of chronic diseases, being a potential tool for classifying preventive and non-preventive behaviors and mitigating chronic diseases.*

**Keywords.** *Ontology, Behavior Classification, Chronic Diseases, Risk Factors, Knowledge Model*

**Resumo.** *Doenças crônicas estão entre as principais causas de morte em todo o mundo. Os fatores de risco relacionados com doenças crônicas estão correlacionados com o estilo de vida das pessoas, e mudanças precoces podem prevenir mortes por doenças crônicas. Este artigo propõe uma ontologia denominada B-Track Onto para classificação de comportamentos que atenuam ou agravam os fatores de risco associados às doenças crônicas. O conjunto de dados MIMIC-III foi utilizado como base para importar 21 pacientes de amostras*

*clínicas. A B-Track Onto inferiu todos os pacientes importados e os categorizou nas classes esperadas. Este trabalho executou também consultas SPARQL para responder às questões de competência, que retornaram os resultados esperados para cada questão. Além disso, houve uma avaliação da ontologia com 10 pacientes durante 4 semanas, mostrando a capacidade da ontologia em inferir comportamentos relacionados a fatores de risco de doenças crônicas durante o dia-a-dia dos pacientes. A partir desta avaliação, foi possível inferir os hábitos preventivos e não preventivos dos pacientes em relação às doenças crônicas. B-Track Onto é uma ontologia que correlaciona comportamento humano e fatores de risco de doenças crônicas, sendo uma potencial ferramenta para classificação de comportamentos preventivos e não preventivos e mitigação de doenças crônicas.*

**Palavras-Chave.** *Ontologia, Classificação de Comportamentos, Doenças Crônicas, Fatores de Risco, Modelo de Conhecimento*

## 1. Introdução

A Organização Mundial de Saúde (OMS) define as doenças crônicas não transmissíveis (DCNTs), também conhecidas como doenças crônicas, como doenças de longa duração resultantes de uma combinação de fatores genéticos, fisiológicos, ambientais e comportamentais [WHO 2023a]. As doenças cardiovasculares, o câncer, as doenças respiratórias crônicas e a diabetes são as DCNTs com o maior número de mortes no mundo, representando 41 milhões de pessoas todos os anos, o equivalente a 71% de todas as mortes globais [WHO 2020a].

Comportamentos como consumo de tabaco, falta de atividade física, pressão arterial elevada e sobrepeso estão entre os principais fatores de risco associados às DCNTs. Sendo assim, mudanças precoces para um estilo de vida saudável podem prevenir as DCNTs e, assim, reduzir o número de mortes. Essas mudanças podem incluir a redução do uso de tabaco e álcool, a prática de exercícios físicos e uma dieta saudável. Além disso, a promoção de um estilo de vida mais saudável é uma forma de baixo custo para os países salvarem vidas e realizarem um impulso econômico [WHO 2023a]. Dessa forma, compreender o comportamento humano associado ao modo de viver é relevante para promover hábitos saudáveis [Griffiths et al. 2020, Rehackova et al. 2020].

A tecnologia pode ser usada como instrumento para auxílio à previsão do comportamento humano e também dos principais eventos que promovem resultados para melhorias no estilo de vida, principalmente facilitando a adoção de hábitos saudáveis [Milne-Ives et al. 2020a]. A variedade de sensores móveis e vestíveis aumentou e ganhou destaque na computação ubíqua [Weiser 1999, Bavaresco and Barbosa 2023]. Esses sensores podem monitorar as atividades do paciente, permitindo que algoritmos analisem os dados coletados para compreender os comportamentos de saúde. Portanto, medidas preventivas podem usar sensores móveis e vestíveis para rastreamento contínuo de condições anormais [Nasiri and Khosravani 2020a].

O processo de evolução tecnológica permitiu que a computação ubíqua fosse empregada em diferentes áreas, destacando-se entre elas a saúde e o

bem-estar [Tavares et al. 2023, Rentz et al. 2023, Dias et al. 2020, Camboim et al. 2023, Larentis et al. 2023, Paula et al. 2022a, Heckler et al. 2023, Büttendbender et al. 2022]. A variedade de dispositivos aumentou a quantidade de dados gerados e permitiu a aplicação de mineração de dados e o reconhecimento de padrões na saúde [Goetz et al. 2022, Heckler et al. 2022, Dias et al. 2022, Paula et al. 2022b].

Diferentes tecnologias podem ser usadas para acompanhamento e prevenção de DCNTs. A ontologia é uma delas, fornecendo um modelo para organizar, estruturar e consultar as entidades de especificações de alto nível de um domínio de conhecimento. Assim, uma ontologia ajuda a anotar um tipo variado de dados de saúde com metadados semânticos, permitindo padronização de dados, consciência de situação, descoberta e integração [Chatterjee et al. 2021a].

Devido à capacidade das ontologias de representar formalmente o conhecimento sobre os domínios, elas permitem descobrir novos fatos através de inferências. Assim, os sistemas computacionais que incorporam essa capacidade fornecem aos usuários novas informações, ajudando-os na adoção de comportamentos saudáveis. Desta forma, ontologias podem ser aplicadas como bases de conhecimento, sendo parte em Sistemas de Informação que sejam orientados à saúde, educação, agronomia e outras aplicações voltadas à sociedade. Considerando esse cenário, este trabalho propõe-se a responder a seguinte questão de pesquisa: Como integrar o uso de tecnologias e análises avançadas de dados para identificar comportamentos de risco associados às DCNTs?

Para responder essa questão de pesquisa, a contribuição científica deste artigo consiste na criação da B-Track Onto, uma ontologia que permite a inferência de comportamentos de pacientes que estão relacionados com os fatores de risco associados às DCNTs. A B-Track Onto permite que regras relacionem os comportamentos com as doenças crônicas através de um nível de probabilidade definido, diferenciando a ontologia proposta de outras já pesquisadas. Assim, como preconizado no trabalho de Pereira e Baranauskas [2017], esta ontologia pode ser usada como um componente em sistemas computacionais para ajudar pacientes e cuidadores em Sistemas de Informação orientados ao tratamento ou prevenção de doenças crônicas. Além disso, pode ser usada para sistemas holísticos que visam ao bem estar dos usuários. Esses sistemas poderiam se beneficiar das regras cadastradas na ontologia para realizar inferências e definir se os pacientes possuem comportamentos saudáveis ou não e determinar os impactos desses na saúde dos pacientes.

A B-Track Onto enfrenta o desafio de se adequar ao contexto social, que envolve as complexidades em que as pessoas vivem, interagem, desenvolvem suas culturas e valores [Pereira and Baranauskas 2017]. Um dos desafios atuais na área de Sistemas de Informação com o qual essa ontologia se depara é como coletar dados dos usuários sem violar leis de proteção a dados, mantendo o anonimato. Nesse sentido, torna-se necessária a utilização de camadas de criptografia e anonimização dos dados coletados. Além disso, também é necessário garantir o consentimento dos usuários sobre a coleta de dados, promovendo transparência sobre quais dados serão coletados e como eles serão utilizados.

Desta forma, este artigo consiste em uma versão estendida do texto publicado por Dias et al. [2023] no Simpósio Brasileiro de Sistemas de Informação em 2023. O

artigo propõe a B-Track Onto, um ontologia para classificar comportamentos associados a fatores de risco de doenças crônicas. Nessa versão consta a ampliação de aspectos metodológicos e da solução técnica, além de novas avaliações da ontologia, utilizando testes unitários e um experimento com 10 usuários durante 4 semanas.

O artigo está dividido em 8 seções. A Seção 2 apresenta o referencial teórico do trabalho. A Seção 3 revisa os trabalhos relacionados que desenvolveram ontologias relacionadas a DCNTs e ao comportamento humano. A Seção 4 apresenta a ontologia B-Track Onto, sendo sua implementação apresentada na Seção 5 e sua validação na seção 6. A Seção 7 apresenta as questões éticas envolvendo a avaliação da ontologia. Por fim, a Seção 8 aborda as considerações finais sobre este trabalho.

## 2. Referencial Teórico

Esta seção apresenta conceitos fundamentais que envolvem o desenvolvimento de uma ontologia para classificação de comportamentos associados a fatores de risco de doenças crônicas. O texto elenca aspectos humanos e tecnológicos presentes na literatura que contribuem para o entendimento deste trabalho.

### 2.1. Doenças Crônicas e Fatores de Risco

Doenças crônicas são 7 das 10 principais causas de morte em todo o mundo. Este fato revela a necessidade de prevenir e tratar as DCNTs, como as doenças cardiovasculares, o câncer, a diabetes e as doenças respiratórias crônicas [WHO 2021]. Diabetes, demência e doenças cardíacas estão entre as principais causas de morte em todo o mundo, sendo as doenças cardíacas as mais representativas. As doenças cardíacas aumentaram de 2 milhões para 9 milhões no período de 2000 a 2019, representando 16% do total de mortes globais. No mesmo período, as mortes globais por diabetes aumentaram 70%, sendo 80% entre os homens, representando o maior aumento percentual de todas as mortes [WHO 2020b].

No âmbito de condições crônicas, a depressão é uma condição mental associada ao comprometimento funcional e à alta morbidade e mortalidade [Sasseville et al. 2021]. Ao longo dos anos, os casos de depressão aumentaram devido a uma complexa interação de fatores sociais, psicológicos e biológicos. Pessoas que passaram por eventos adversos na vida, como desemprego, morte ou trauma psicológico, têm maior probabilidade de desenvolver transtornos depressivos [WHO 2017].

A OMS categoriza os fatores de risco associados às DCNTs em dois tipos principais, sendo eles comportamentos modificáveis e metabólicos [WHO 2023a, WHO 2023b]. Exemplos de comportamentos modificáveis são dietas pouco saudáveis, consumo de álcool, uso de tabaco e sedentarismo. Os exemplos de fatores de risco metabólicos são aumento da pressão arterial, obesidade, hiperglicemia<sup>1</sup> e hiperlipidemia<sup>2</sup>. O aumento da pressão arterial é responsável por 19% das mortes em todo o mundo, seguido pelo excesso de peso, obesidade e pelo aumento da glicemia [WHO 2023a].

---

<sup>1</sup> A hiperglicemia é caracterizada por níveis elevados de glicose no sangue.

<sup>2</sup> A hiperlipidemia é caracterizada por altos níveis de gordura no sangue.

Além disso, o consumo excessivo de sódio é responsável por 4,1 milhões de mortes anuais, e o uso do tabaco está associado a mais de 7,2 milhões de mortes todos os anos [Kyada and Baria 2019]. Além disso, o consumo de álcool é responsável por mais de 1,7 milhões de mortes anuais [Monteiro et al. 2018], enquanto estilos de vida pouco saudáveis causam 1,6 milhões de mortes anualmente [El-Gayar et al. 2020].

## 2.2. Comportamentos Humanos e DCNTs

Os comportamentos humanos podem prevenir ou promover o desenvolvimento de DCNTs. Os comportamentos preventivos são comumente hábitos saudáveis que protegem os indivíduos do desenvolvimento de doenças crônicas. Por outro lado, comportamentos não preventivos estão associados a fatores de risco, aumentando a probabilidade de uma pessoa desenvolver uma DCNT.

Manter um estilo de vida saudável pode prevenir as DCNTs e, assim, reduzir o número de mortes. Portanto, controlar os comportamentos associados aos fatores de risco pode reduzir a prevalência das DCNTs. Esse controle pode ser realizado através de mudanças precoces no estilo de vida das pessoas, a fim de promover hábitos mais saudáveis. Essas mudanças podem incluir a redução do uso de tabaco e álcool, aumentar a prática de exercícios e realizar uma dieta saudável. As mudanças nos hábitos trazem benefícios com baixo custo para governos salvarem vidas e proverem um impulso econômico [WHO 2023a]. Por isso, é estratégico entender quais comportamentos humanos estão mais associados a fatores de risco das DCNTs [Griffiths et al. 2020, Rehackova et al. 2020].

A manutenção do engajamento de um indivíduo em um novo estilo de vida saudável pode ser considerada um desafio a ser enfrentado por novas tecnologias. Considerando esse cenário, Brown et al. [2016] citam a gamificação como um exemplo de técnica que promove o engajamento. Essa técnica pode ser usada como estratégia para motivar e envolver usuários em aplicações educacionais, empresariais e de saúde. Este mecanismo permite a utilização de dinâmicas e mecânicas de jogos em aplicações computacionais de forma a envolver os usuários em um estilo de vida saudável [Dalmina et al. 2022]. A B-Track Onto poderia fornecer dados de comportamentos preventivos praticados pelos usuários, os quais poderiam, por exemplo, servir de pontuação em um Sistema de Informação Gamificado.

A tecnologia pode ser usada para explicar e prever o comportamento humano e eventos-chave que geram resultados para melhorias no estilo de vida e facilitam a adoção de comportamentos saudáveis [Milne-Ives et al. 2020b]. A popularização de dispositivos móveis e vestíveis contendo uma grande variedade de sensores facilitou o monitoramento das atividades dos pacientes. Além disso, a coleta de uma quantidade maior de dados de sensores contribuiu para algoritmos analisarem e compreenderem os comportamentos de saúde, cenário que pode ser explorado por medidas preventivas para DCNTs [Nasiri and Khosravani 2020b, Bavaresco and Barbosa 2023].

## 2.3. Ontologias

De acordo com Gruber [1993], ontologias são especificações explícitas de uma conceitualização, ou seja, conjuntos estruturados de termos e conceitos que representam

conhecimentos sobre o mundo. Na computação ubíqua, as ontologias exercem relevância e importância devido à necessidade de representação semântica para que tanto os computadores quanto os usuários possam compreender as representações. Em uma base de conhecimento, todas as entidades têm definições e restrições e se relacionam de acordo com as relevâncias de interesses, que, em suma, auxiliam na obtenção do resultado.

Ontologias são formadas por componentes como conceitos, relacionamentos, axiomas e instâncias, onde conceitos possuem hierarquias como classes e subclasses, podendo ser definições abstratas (comportamento) ou concretas (pessoa). Os relacionamentos entre conceitos tornam-se propriedades entre esses objetos, como, por exemplo, o relacionamento entre uma pessoa e um comportamento. Os axiomas representam regras para caracterizar entidades. Um exemplo de axioma seria afirmar que todo paciente é uma pessoa. As instâncias são um conhecimento prévio existente na ontologia [GUIMARAES 2003].

A ontologia permite anotar um tipo variado de dados de saúde com metadados semânticos, permitindo padronização de dados, consciência situacional, descoberta e integração [Chatterjee et al. 2021b]. Assim, essa técnica fornece uma estrutura de alto nível de um domínio de conhecimento que foca em organizar, estruturar e consultar as entidades definidas nela.

Mapear entidades reais para entidades que computadores entendam semanticamente facilita o compartilhamento e o reúso da informação, uma vez que a maioria das ontologias encontra-se disponível em meios eletrônicos para complementação. Segundo Genesereth e Nilsson [1987], toda a base de conhecimento é estabelecida em uma conceitualização de objetos e entidades que se relacionam e possuem áreas de interesse. Uma conceitualização é uma visão simplificada e até mesmo abstrata de uma representação visando a um propósito. Outros autores como Gruber [1993] definem a ontologia como uma especificação explícita de um conceito. Computadores podem inferir informações de novos e mais completos contextos, determinar compatibilidades ou realizar comparações entre fatos [Krummenacher and Strang 2007].

### **3. Trabalhos relacionados**

Este artigo revisou trabalhos da literatura que tinham por objetivo desenvolver ontologias para inferir comportamentos humanos relacionados às DCNTs. Essa seção aborda esses trabalhos relacionados, os quais foram selecionados de acordo com a metodologia descrita na Subseção 3.1. O processo de análise dos artigos encontrados utilizando uma *string* de busca resultou em sete trabalhos que foram selecionados como base para a pesquisa, os quais foram analisados e descritos resumidamente na Subseção 3.2. A Subseção 3.3 compara os trabalhos relacionados com a ontologia proposta.

#### **3.1. Metodologia**

Petersen et al. [2008] desenvolveram uma metodologia sistemática para executar um processo de pesquisa dividida em três etapas principais: especificação da *string* de busca, seleção das bases de pesquisa e coleta de resultados. A primeira etapa realiza a identificação dos principais termos da área de estudo e seus sinônimos mais relevan-

tes. Este estudo define os termos principais como *Behavior*, *Noncommunicable Diseases* e *Ontology*. A Tabela 1 apresenta esses termos e seus sinônimos relacionados. Os sinônimos para o termo “*Behavior*” estão relacionados ao comportamento humano. Por sua vez, os sinônimos para “*Noncommunicable Diseases*” foram selecionados por meio de termos que permitissem a cobertura das variações do termo “DCNT” e das DCNTs mais comuns [WHO 2023a]. Finalmente, os sinônimos para o termo “*Ontology*” abrangem tópicos relacionados à ciência da informação. Algumas bases possuem limites de termos na *string* de busca e, portanto, esses termos precisam ter baixa ambiguidade para fazer uma busca assertiva.

**Tabela 1. Estrutura da *string* de busca**

Termos principais	Termos da Busca
Behavior	(behavior OR personality OR habit OR attitude) AND
Noncommunicable Diseases	(“noncommunicable diseases” OR “chronic diseases” OR “risk factors” OR “chronic conditions” OR diabetes OR cancer OR “cardiovascular diseases” OR “respiratory diseases” OR depression) AND
Ontology	(ontology OR ontologies OR “Semantic Web” OR “Linked Data”)

Depois de construir a *string* de busca, a próxima etapa seleciona as bases de pesquisa para consulta de artigos. Este estudo considerou as seguintes bases: PubMed Central <sup>3</sup>, ACM Digital Library <sup>4</sup>, IEEE Xplore Digital Library <sup>5</sup>, Springer Library <sup>6</sup>, e Wiley <sup>7</sup>. A primeira base contém artigos que integram trabalhos relacionados às áreas de saúde e tecnologia. As demais são bases renomadas em computação, contendo artigos sobre os diversos temas desta área temática. Para reduzir o viés na pesquisa de artigos, a *string* de busca correspondeu aos campos “Resumo”, “Título” e “Palavra-chave” de cada base de busca.

O processo de busca nas bases de dados ocorreu em Julho de 2022. Após a busca inicial, os artigos selecionados passaram por um processo de filtragem baseado em Critérios de Inclusão (CIs) e Exclusão (CEs). Os CIs serviram como base para seleção do conjunto inicial de artigos. Desta forma, os CIs são os seguintes:

- CI1: O artigo foi publicado em uma conferência, periódico ou *workshop*;
- CI2: O artigo contém os termos da *string* de busca;
- CI3: O artigo foi publicado entre 2018 e 2022;
- CI4: O artigo está escrito em inglês.

Em contrapartida, os CEs foram utilizados nas fases seguintes, a fim de remover ruídos no processo de filtragem, eliminando trabalhos que não estavam relacionados com o escopo da pesquisa. Sendo assim, os CEs são os seguintes:

- CE1: O artigo consiste em uma revisão da literatura ou mapeamento sistemático;

<sup>3</sup><https://www.ncbi.nlm.nih.gov/pmc/advanced>

<sup>4</sup><https://dl.acm.org/search/advanced>

<sup>5</sup><https://ieeexplore.ieee.org/search/advanced>

<sup>6</sup><https://link.springer.com/search>

<sup>7</sup><https://onlinelibrary.wiley.com/search/advanced>

- CE2: O artigo não está relacionado com os temas de pesquisa;
- CE3: O artigo não está disponível como texto completo;
- CE4: O artigo não propõe uma ontologia para a análise de hábitos alimentares e atividades físicas.

Após a realização do processo de filtragem dos artigos com base nos CIs e CEs, foram obtidos sete artigos relacionados. Estes trabalhos propuseram ontologias para a análise de comportamentos relacionados a hábitos alimentares e atividades físicas, para o tratamento e acompanhamento de indivíduos com DCNTs. Para todos os trabalhos selecionados no mapeamento sistemático, foram explorados aspectos de pesquisa, a fim de analisar as seguintes questões:

- Inferências: verifica se o processo de inferência é utilizado na ontologia proposta, possibilitando usar a ontologia para descobrir os relacionamentos entre as entidades do domínio;
- Consulta: verifica se a linguagem de consulta da ontologia é utilizada, possibilitando que sistemas consultem a base de conhecimento contida na ontologia;
- Comportamentos: verifica quais comportamentos humanos são compreendidos pela ontologia, identificando qual é o escopo de conhecimento presente na ontologia;
- Doença crônica: verifica qual é o domínio de DCNTs que a ontologia possui, identificando qual é o escopo de conhecimento presente na ontologia;
- Validação: verifica se a ontologia foi avaliada com dados reais ou simulados, possibilitando entender qual o nível de teste realizado sob a ontologia.

### 3.2. Descrição dos Trabalhos relacionados

Esta subseção descreve os trabalhos relacionados que foram utilizados como base de comparação para o desenvolvimento do trabalho proposto.

#### 3.2.1. *An Ontology-Based Serious Game Design for the Development of Nutrition and Food Literacy Skills*

Mitsis et al. [2019] desenvolveram um jogo sério baseado em ontologia chamado *Express Cooking Train*. Esse sistema foca na alfabetização nutricional e alimentar, visando promover uma mudança de hábitos alimentares. O jogo proposto inspira-se em três gêneros de jogos, sendo eles culinária, *Role-Playing Game* (RPG) e quebra-cabeça. Este jogo sério utiliza uma ontologia que expressa o conhecimento nutricional e alimentar, assim fornecendo conhecimentos de hábitos saudáveis aos jogadores durante o jogo. A ontologia é utilizada para avaliar se o usuário consegue preparar um alimento com alto valor nutricional e sua semelhança com a receita de referência. O usuário enfrenta o desafio de descobrir receitas saudáveis. O jogo não foi avaliado em termos de aceitação do usuário, engajamento e aprendizado.

### 3.2.2. *A health consumer ontology of fast food information*

Amith et al. [2020] apresentaram a *Ontology of Fast Food Facts*, uma base de conhecimento que modela dados nutricionais de consumidores de estabelecimentos de *fast food*. Esta ontologia foi desenvolvida na ferramenta Protégé e serve como uma base de conhecimento agregada para centralizar as informações nutricionais para os consumidores. Para a avaliação da ontologia foram usadas fontes nutricionais publicadas no McDonald's ©, Dairy Queen ©, Chick Fil-A ©, Wendy's © e Taco Bell ©. A ontologia mostrou precisão do conhecimento nutricional e o atendimento aos requisitos de competência em aproximadamente 80% dos casos. O objetivo dessa ontologia é impactar as escolhas alimentares dos consumidores para mitigar graves resultados de saúde, como obesidade, câncer, diabetes e doenças cardiovasculares.

### 3.2.3. *An intelligent fuzzy inference rule-based expert recommendation system for predictive diabetes diagnosis*

Nagaraj e Deepalakshmi [2022] propuseram um modelo que emprega uma técnica de inferência *fuzzy* para diagnósticos preditivos de diabetes, para ser utilizado na recomendação de sistemas especialistas. Uma função de pertinência *fuzzy* baseada na técnica de Mamdani e Assilian [1975] utiliza recomendações médicas e metodologias estatísticas. Depois, especialistas médicos validam as regras baseadas em mineração, usando uma técnica de indução de regras de árvore de decisão. Com base nessas informações, são feitas recomendações para uma vida mais saudável de nutrição, exercícios e medicamentos aos pacientes. O modelo foi avaliado utilizando um conjunto de dados médicos e clínicos. Este conjunto foi oriundo do registro eletrônico de saúde da base de dados de diabetes indiana (PIMA). A combinação das informações de especialistas médicos com técnicas de mineração de dados auxiliou os médicos na prevenção do risco de diabetes em pacientes.

### 3.2.4. *Using Context Ontology and Linear SVM for Chronic Kidney Disease Prediction*

Guermah et al. [2018] propuseram uma arquitetura baseada em ontologia usando Máquina de Vetores de Suporte Linear (SVM) para a previsão de doenças crônicas, considerando especialmente pacientes renais. Essa arquitetura promoveu um alto nível de abstração, benefícios de produtividade e melhoria da qualidade do uso de contexto no campo da *e-Health*. A utilização de técnicas de aprendizado supervisionado e SVM permitiram tratar diferentes tipos de propriedades contextuais, mesmo com falta de dados, e lidar com a grande dimensão de informação da medicina. A avaliação mostrou que o modelo proposto previu todos os 250 pacientes renais e previu 123 das 150 doenças, fornecendo então uma assertividade aproximada de 93,3%.

### 3.2.5. *An Ontology of Psychological Barriers to Support Behaviour Change*

Alfaifi et al. [2018] criaram um modelo ontológico da noção psicológica de barreiras ao comportamento saudável. O modelo considera conceitos que visam a conhecer o comportamento do paciente para encontrar intervenções que promovem um estilo de vida saudável. Esta ontologia apoia a seleção de intervenções motivacionais para promover mudanças comportamentais nos pacientes. A ontologia foi construída utilizando a *Ontology Web Language* (OWL) de uma forma genérica e expansível para novos comportamentos e doenças. Este modelo foi desenvolvido e avaliado para o comportamento da atividade física para diabetes do tipo 2. No entanto, a abordagem pode ser generalizada ou estendida para várias condições em que se procura modelar motivação e aconselhamento motivacional.

### 3.2.6. *Evolving Medical Ontologies Based on Causal Inference*

Hu e Kerschberg [2018] apresentaram uma nova metodologia para estender e melhorar uma ontologia com conhecimento obtido por inferência. Foi utilizada a estrutura hierárquica das variáveis de sintomas do paciente com base no Dicionário Médico para Terminologia de Atividades Regulatórias (MedDRA). Essa estrutura foi inserida para o aprendizado de uma Rede Bayesiana Causal (CBN) usando Max-Min Hill-Climbing (MMHC), uma restrição híbrida e um algoritmo de aprendizado baseado em pontuação, no estudo pré-existente do *National Institutes of Mental Health* (NIMH) sobre tratamento de pacientes para aliviar a depressão. Essa extensão permitiu uma ontologia informativa, abrindo novas possibilidades de ferramentas para tomada de decisão para médicos e pacientes.

### 3.2.7. *Towards Consistent Data Representation in the IoT Healthcare Landscape*

Reda et al. [2018] propuseram um modelo de dados semânticos chamado IFO. Este modelo representa os dados de saúde dos pacientes e possui a aptidão de integrar e trocar fontes heterogêneas de *Internet of Things* (IoT). A ontologia representa formalmente os conceitos comuns de dispositivos IoT *fitness* e aparelhos de bem-estar. A IFO descreve os dados de IoT não apenas por seu valor de medição, mas também por seus relacionamentos com outras fontes de dados e com propriedades descritivas como, onde e quando os dados foram produzidos. Esta ontologia forneceu a representação de conhecimento de fontes de dados semiestruturadas. Além disso, forneceu conjuntos de dados de domínio para construir um modelo de dados interligado, unificando e habilitando capacidades de raciocínio semântico, facilitando o compartilhamento, a exploração e a reutilização de fontes de dados de saúde e condicionamento físico da IoT.

## 3.3. Comparativo dos trabalhos relacionados em relação à B-Track Onto

A Tabela 2 apresenta a comparação entre a B-Track Onto e os trabalhos relacionados, considerando os aspectos de pesquisa destacados na Subseção 3.1. O objetivo da comparação consiste em analisar os recursos presentes em cada uma das ontologias.

**Tabela 2. Comparativo dos trabalhos relacionados**

Artigos	Inferências	Consulta	Comportamento	Doença crônica	Validação
[Mitsis et al. 2019]	Não	Não	Hábitos alimentares	Doenças crônicas relacionadas à obesidade	Não avaliada
[Amith et al. 2020]	Não	Sim	Não	Doenças crônicas relacionadas à obesidade	Avaliada com dados nutricionais de empresas de <i>Fast Food</i>
[Nagaraj and Deepalakshmi 2022]	Sim	Não	Não	Diabetes	Avaliada com o <i>dataset</i> do Instituto Nacional de Diabetes e Doenças Digestivas e Renais
[Guermah et al. 2018]	Sim	Não	Não	Doença Crônica Renal	Avaliada com o <i>dataset</i> de Doença Renal Crônica de Estágio Inicial Indiana
[Alfaifi et al. 2018]	Não	Não	Atividade Física	Diabetes	Não avaliada
[Hu and Kerschberg 2018]	Sim	Sim	Fobia, Pânico, Uso de Drogas e Álcool, distúrbio de sono	Distúrbios mentais	Avaliada com o <i>dataset</i> STAR*D
[Reda et al. 2018]	Sim	Sim	Não	Geral	Não avaliada
B-Track Onto	Sim	Sim	Geral	Geral	Avaliada com o <i>dataset</i> MIMIC-III

Considerando os resultados obtidos através do mapeamento sistemático, não foi identificada uma ontologia que analisasse todos os hábitos comportamentais dos pacientes e inferisse quais são os comportamentos relacionados com os fatores de risco associados às DCNTs, permitindo inferir a suscetibilidade que o paciente tem para desenvolver ou agravar uma DCNT. Considerando essa lacuna de pesquisa, esse artigo apresenta como contribuição científica a proposta de uma ontologia denominada B-Track Onto, que será apresentada nas próximas seções.

#### 4. Modelagem da B-Track Onto

Este trabalho apresenta uma pesquisa descritiva e exploratória dos fatos e fenômenos que são relacionados a comportamentos humanos e DCNTs. A ontologia proposta realiza inferências sobre comportamentos humanos, categorizando-os como preventivos e não preventivos ao associá-los com fatores de risco e a suscetibilidade do desenvolvimento de uma DCNT.

A metodologia aplicada na criação da ontologia consistiu em mapear conceitos relacionados a comportamentos humanos e DCNTs. A primeira fase envolveu a elaboração de questões de validação para modelar e avaliar a ontologia, conforme proposto na metodologia de Grüninger e Fox [1995]. A segunda fase permitiu a identificação das principais características que determinam comportamentos preventivos e não preventivos, correlacionando esses comportamentos com os fatores de risco e com as principais categorias de

DCNTs, já identificadas pela OMS. As próximas subseções apresentam as classes e as correlações presentes na ontologia.

#### 4.1. Cenário de Motivação

O cenário de motivação descreve uma situação base em que as aplicações podem utilizar a ontologia. Portanto, o cenário de motivação considerou duas características do cuidado às DCNTs. Primeiro, o controle dos fatores de risco pode prevenir doenças não transmissíveis, como câncer, derrame ou doenças cardíacas. Além disso, alguns fatores de risco, como tabagismo e obesidade, são gerados pela influência de comportamentos humanos. Assim, o seguinte cenário orienta a construção da ontologia proposta:

*O B-Track é um assistente pessoal para dispositivos móveis que visa auxiliar no tratamento de pacientes com DCNTs. Este assistente usa contexto de dados e questionários autogerenciados para recomendar hábitos que podem beneficiar a saúde. Este assistente analisa se os usuários estão praticando as recomendações feitas. A B-Track Onto é uma ontologia que suporta inferências focadas nas recomendações do B-Track.*

#### 4.2. Questões de Competência

Com base no cenário, foram elaboradas sete Questões de Competência (QCs) conforme proposto na metodologia de Grüniger e Fox [1995]. Essas questões guiam a avaliação, identificando se a ontologia satisfaz o domínio proposto. As questões utilizaram linguagem natural, visando ao domínio dos comportamentos humanos relacionados aos fatores de risco em DCNTs, como segue:

- QC1. Dado um comportamento, quais tipos de DCNTs são suscetíveis?
- QC2. Dado um paciente, a que tipos de DCNTs ele é suscetível?
- QC3. Dado um paciente, quais comportamentos aumentam a probabilidade de desenvolver uma DCNT?
- QC4. Dado um paciente, que tipo de fator de risco é metabólico?
- QC5. Dado um paciente, que tipo de fator de risco é de comportamento modificável?
- QC6. Dado um paciente, que comportamento preventivo ele precisa fazer?
- QC7. Dadas as recomendações ao paciente, quais delas geraram uma mudança para um comportamento preventivo?

A QC1 tem por objetivo validar se a ontologia consegue inferir a correlação de um comportamento com os fatores de risco que levam a uma DCNT. O objetivo da QC2 é validar a capacidade da ontologia em identificar as DCNTs a que um paciente está suscetível com base nos seus comportamentos. A QC3 valida a inferência da ontologia na identificação dos níveis de probabilidade do desenvolvimento de DCNTs.

As questões QC4 e QC5 visam validar a identificação do tipo de um fator de risco através das inferências realizadas pela ontologia. A QC6 valida se a ontologia infere quais são os comportamentos preventivos que o usuário deveria praticar. Por fim, a QC7 visa identificar se a ontologia permite um acompanhamento dos comportamentos praticados do usuário para avaliar se ele está praticando hábitos preventivos às DCNTs.

### 4.3. Ontologia B-Track Onto

A ontologia contempla as classes necessárias para reconhecer os comportamentos relacionados aos fatores de risco, como, por exemplo, consumo de tabaco, sódio ou exposição ao sol, que foram mapeados pela OMS [WHO 2023a].

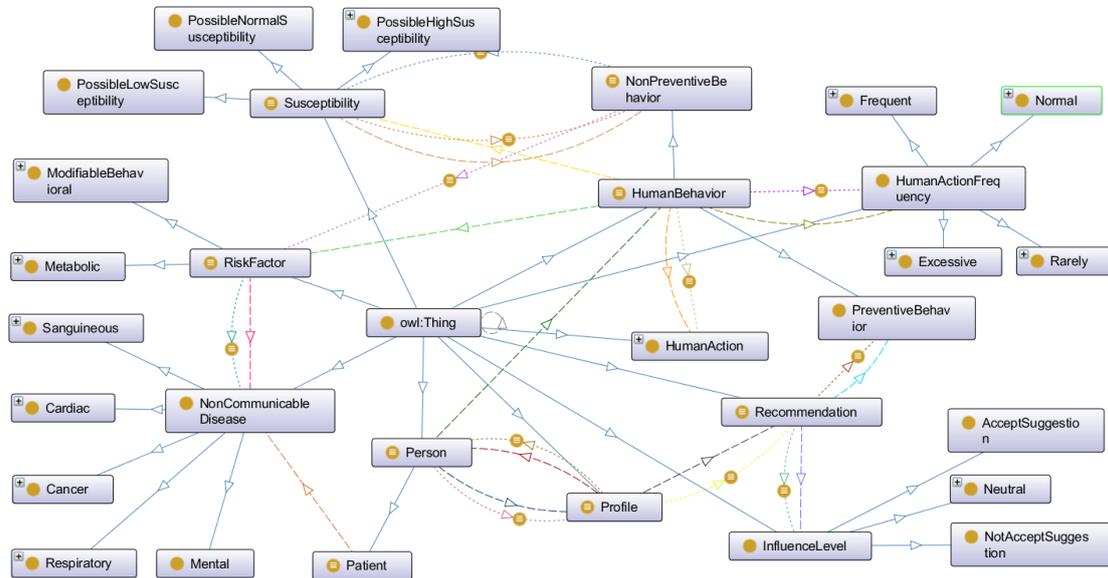


Figura 1. Visão hierárquica da B-Track Onto.

A Figura 1 apresenta a ontologia, destacando as relações entre os conceitos envolvendo comportamentos humanos, fatores de risco e DCNTs. A modelagem foi realizada de forma a categorizar comportamentos, suas frequências e suscetibilidade com os fatores de risco, possibilitando novas correlações. Desta forma, a ontologia possui a classe *HumanAction* à qual são atribuídas as ações humanas. A frequência dessas ações são atribuídas à classe *HumanActionFrequency*. A classe *HumanBehavior* representa o comportamento humano na ontologia. O comportamento é composto pela associação de uma ação humana e uma frequência.

A OMS categoriza os fatores de risco como fatores metabólicos ou modificáveis [WHO 2023b], que são atribuídos pela classe *RiskFactor* e suas subclasses *Metabolic* e *ModifiableBehavioral*. A suscetibilidade do fator de risco acontecer é descrita na classe *Susceptibility* e possui três subclasses: 1) *PossibleLowSusceptibility*: representa uma baixa possibilidade de desenvolver uma DCNT para um determinado fator de risco, 2) *PossibleNormalSusceptibility*: representa uma possibilidade normal de desenvolvimento de uma DCNT dado um determinado fator de risco e 3) *PossibleHighSusceptibility*: representa uma alta possibilidade do fator de risco causar uma DCNT.

A classe *NonCommunicableDisease* possui cinco subclasses às quais são atribuídas as doenças crônicas, sendo elas: *Cancer*, *Cardiac*, *Mental*, *Respiratory* e *Sanguineous*. Uma pessoa sem doenças crônicas é representada na ontologia pela classe *Person*. Quando uma pessoa estiver associada a uma doença crônica, ela é atribuída à subclasse *Patient*, a qual é uma especialização da classe *Person*. A classe *Profile* representa

os perfis que reúnem pessoas com comportamentos similares e possui recomendações de comportamentos preventivos oriundas da classe *Recommendation*. *InfluenceLevel* é a classe que representa o nível de influência dessa recomendação, e possui três subclasses: 1) *AcceptSuggestion*: indica quando uma sugestão é aceita pelo usuário, 2) *Neutral*: indica neutralidade de aceitação do usuário, e 3) *NotAcceptSuggestion*: indica que o usuário não aceita a sugestão.

Nesta proposta, um comportamento humano está associado à uma ação e uma frequência. Além disso, este comportamento possui uma suscetibilidade relacionada a um fator de risco, que está relacionado com DCNTs. As recomendações possuem níveis de influência e estão associadas a perfis de pessoas. A B-Track Onto infere comportamentos humanos a partir das regras estabelecidas, classificando esses comportamentos. Assim, essa classificação permite identificar os fatores de risco relacionados com estes comportamentos humanos de forma automática.

## 5. Aspectos de implementação da ontologia

A ontologia B-Track Onto foi implementada utilizando o software Protégé<sup>8</sup> e a linguagem OWL [Musen and Team 2015]. A Tabela 3 apresenta métricas da ontologia extraídas da ferramenta Protégé após sua implementação. A Tabela 3 mostra o total de axiomas, classes, subclasses, propriedades e indivíduos da B-Track Onto. Os axiomas são expressões lógicas que definem um conceito. As métricas “Total de classes” e “Total de subclasses” representam a quantidade de classificações encontradas na ontologia. As propriedades de objeto indicam os relacionamentos entre instâncias de duas classes. As próximas subseções apresentam a implementação de axiomas e relacionamentos.

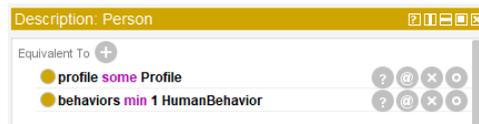
**Tabela 3. Métricas da ontologia B-Track Onto**

Métricas	Valores
Axiomas	13
Total de classes	10
Total de subclasses	20
Total de propriedades de objetos	14

### 5.1. Terminologia de axiomas

Os axiomas e relacionamentos definidos para as classes da B-Track Onto permitem a ontologia categorizar instâncias automaticamente. A Figura 2 apresenta os axiomas de equivalência da classe *Person*. Uma instância é categorizada como pessoa quando ela possuir no mínimo um comportamento humano ou estar associada a algum perfil. A Figura 3 apresenta a subclasse *Patient* da classe *Person*, que possui um axioma de equivalência definindo como paciente uma pessoa que possua no mínimo uma DCNT associada a ela.

<sup>8</sup><https://protege.stanford.edu/software.php>



**Figura 2. Expressões lógicas que descrevem o axioma de equivalência para o conceito da classe *Person*.**



**Figura 3. Expressão lógica que descreve o axioma de equivalência para o conceito da subclasse *Patient*.**

A classe *HumanBehavior* possui duas definições de axiomas de equivalência, que são apresentadas na Figura 4. A categorização de uma instância como um comportamento humano dependerá dessa instância ter alguma ação humana e alguma frequência. A Figura 5 mostra os axiomas de equivalência da subclasse *NonPreventiveBehavior*, na qual um comportamento é categorizado como não preventivo se o mesmo possuir algum fator de risco e uma suscetibilidade vinculada.

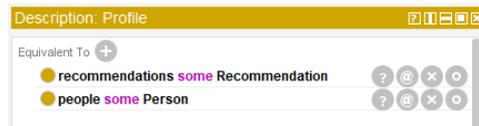


**Figura 4. Expressões lógicas que descrevem os axiomas de equivalência para o conceito da classe *HumanBehavior*.**



**Figura 5. Expressões lógicas que descrevem os axiomas de equivalência para o conceito da subclasse *NonPreventiveBehavior*.**

A Figura 6 apresenta os axiomas de equivalência da classe *Profile*, indicando que para uma instância ser categorizada como perfil, ela precisa ter alguma recomendação e alguma pessoa vinculada para ser inferida a equivalência. A classe *Recommendation* possui dois axiomas de equivalência. A Figura 7 mostra esses axiomas em que uma instância de recomendação precisa ter algum comportamento preventivo e algum nível de influência.



**Figura 6. Expressões lógicas que descrevem os axiomas de equivalência para o conceito da classe *Profile*.**



**Figura 7. Expressões lógicas que descrevem os axiomas de equivalência para o conceito da classe *Recommendation*.**

Uma instância será categorizada como um fator de risco (classe *RiskFactor*), quando ela estiver associada com alguma DCNT (Figura 8). Esse axioma permite que através de um fator de risco seja possível identificar a doença crônica vinculada a ele. A Figura 9 apresenta o axioma de equivalência da classe *Susceptibility* indicando que uma instância de suscetibilidade precisa ter algum comportamento não preventivo, permitindo inferir o quão suscetível uma pessoa pode estar a desenvolver uma DCNT com base no seu comportamento.



**Figura 8. Expressão lógica que descreve o axioma de equivalência para o conceito da classe *RiskFactor*.**



**Figura 9. Expressão lógica que descreve o axioma de equivalência para o conceito da classe *Susceptibility*.**

## 5.2. Terminologia de relacionamentos

Além dos axiomas de equivalência, foram definidas propriedades de objetos que criam relacionamentos entre classes. A Figura 10 representa todas as propriedades de objetos definidas para a B-Track Onto. A propriedade *has* é uma abstração genérica que correlaciona a classe principal *Thing*. Assim, pode-se definir que uma instância da classe *Thing* possui uma propriedade *has* para outra instância da classe *Thing*. As sub-propriedades relacionadas às classes específicas são apresentadas a seguir.

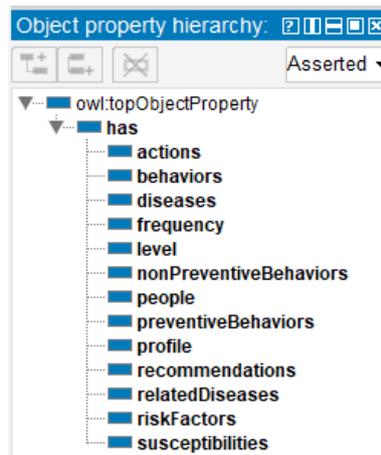


Figura 10. Propriedades de Objetos do B-Track Onto.

Um comportamento humano é representado pela classe *HumanBehavior* e possui quatro propriedades que correlacionam essa classe com outras, sendo elas: 1) a propriedade *actions*, que correlaciona as ações humanas (classe *HumanAction*); 2) *frequency*, que correlaciona a frequência da ação humana (classe *HumanActionFrequency*); 3) a propriedade *riskFactors*, que correlaciona os fatores de risco; e 4) *susceptibilities*, que correlaciona a suscetibilidade associada de um comportamento humano a um fator de risco. As propriedades 1 e 2 são genéricas e permitem representar vários comportamentos humanos, enquanto as propriedades 3 e 4 fornecem informações dos possíveis problemas que este comportamento gera.

Uma pessoa (classe *Person*) possui duas propriedades, sendo a primeira *behaviors* vinculando uma pessoa com os comportamentos humanos (classe *HumanBehavior*) e a segunda propriedade *profile*, que correlaciona um perfil (classe *Profile*) com uma pessoa. Por sua vez, a subclasse *Patient* possui a propriedade *diseases*, que vincula as DCNTs (classe *NonCommunicableDisease*) ao paciente.

O perfil (classe *Profile*) possui duas propriedades, sendo a primeira a *people*, que vincula as pessoas que contêm aquele perfil, e a segunda a *recommendations*, a qual vincula as recomendações (classe *Recommendation*) do perfil. Uma recomendação possui a propriedade *level*, que vincula o nível de influência (classe *InfluenceLevel*) da recomendação e a propriedade *preventiveBehaviors*, que vincula os comportamentos preventivos (classe *PreventiveBehavior*).

A propriedade *nonPreventiveBehaviors* correlaciona a classe de suscetibilidade com a subclasse *NonPreventiveBehavior*. A classe *RiskFactor* possui a propriedade *relatedDiseases*, que realiza o vínculo com a classe *NonCommunicableDisease*.

## 6. Avaliação e Resultados

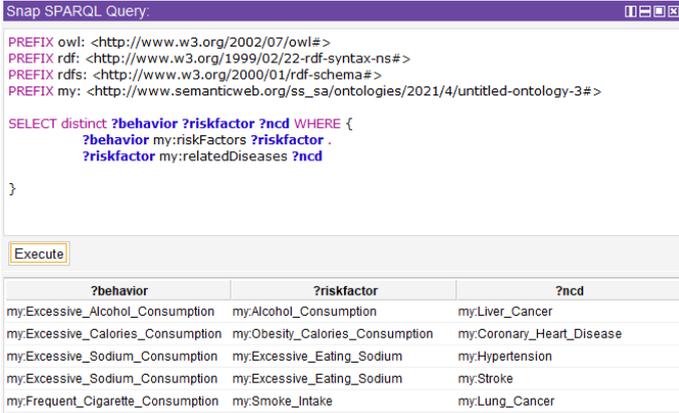
As QCs propostas na metodologia de Grüninger e Fox [1995] e apresentadas na Subseção 4.2 orientaram a avaliação da ontologia. Essas questões avaliaram se a ontologia satisfaz

o domínio proposto. Para que a avaliação ocorresse com o processo de *reasoning*<sup>9</sup> automaticamente, foram criadas instâncias que abrangessem fatores de risco e DCNTs. O *dataset* MIMIC-III [Johnson et al. 2016] possui amostras laboratoriais gerais de 100 pacientes, em que foi realizado um pré-filtro através do Grupo Relacionado ao Diagnóstico (DRG) e foram identificados 21 indivíduos com algum fator de risco relacionado à uma DCNT. As expressões lógicas mostradas na seção anterior foram processadas pelo *reasoner*<sup>10</sup> Hermit<sup>11</sup>.

Após o cadastro das instâncias no Protégé, foi executado o *reasoner*, que as inferiu através das associações definidas nos axiomas. A Figura 11 apresenta as instâncias identificadas automaticamente pelo *reasoner*, sendo destacadas duas instâncias, em que o paciente “subject\_10026” foi identificado apenas pela DCNT e o “subject\_42231”, além da DCNT, pelo perfil. Com as associações sendo inferidas corretamente, foram executadas 6 consultas, utilizando a linguagem SPARQL, para responder cada uma das QCs.

A Figura 12 mostra o resultado da consulta utilizada para responder a QC1, na qual cada linha apresenta um comportamento, o fator de risco associado e a DCNT correlacionada. Através do comportamento humano foi possível inferir os fatores de risco associados e retornar as DCNTs às quais uma pessoa com este estilo de vida está suscetível. Nesta consulta é possível ver que o consumo excessivo de sódio está relacionado com o desenvolvimento de hipertensão, através do fator de risco de comer sódio em excesso.

A validação da QC2 foi realizada através da consulta específica ao paciente “subject\_10019”, apresentada na Figura 13. O resultado mostra que este paciente está altamente suscetível a desenvolver câncer de fígado, devido ao seu comportamento não preventivo de consumir álcool em excesso (*Excessive\_Alcohol\_Consumption*).



```

PREFIX owl: <http://www.w3.org/2002/07/owl#>
PREFIX rdf: <http://www.w3.org/1999/02/22-rdf-syntax-ns#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
PREFIX my: <http://www.semanticweb.org/ss_sa/ontologies/2021/4/untitled-ontology-3#>

SELECT distinct ?behavior ?riskfactor ?ncd WHERE {
  ?behavior my:riskFactors ?riskfactor .
  ?riskfactor my:relatedDiseases ?ncd
}

```

?behavior	?riskfactor	?ncd
my:Excessive_Alcohol_Consumption	my:Alcohol_Consumption	my:Liver_Cancer
my:Excessive_Calories_Consumption	my:Obesity_Calories_Consumption	my:Coronary_Heart_Disease
my:Excessive_Sodium_Consumption	my:Excessive_Eating_Sodium	my:Hypertension
my:Excessive_Sodium_Consumption	my:Excessive_Eating_Sodium	my:Stroke
my:Frequent_Cigarette_Consumption	my:Smoke_Intake	my:Lung_Cancer

**Figura 12. Resultado da consulta das DCNTs suscetíveis a um comportamento.**

<sup>9</sup>*Reasoning* é um processo de inferências lógicas de um conjunto de fatos ou axiomas.

<sup>10</sup>Um *reasoner* é um software capaz de inferir consequências lógicas de um conjunto de fatos ou axiomas afirmados.

<sup>11</sup>Hermit é um conhecido *reasoner* de ontologias para a linguagem OWL, incluída no Protégé

Figura 11. Resultados obtidos com a execução do reasoner Hermit.

```

Snap SPARQL Query:
PREFIX owl: <http://www.w3.org/2002/07/owl#>
PREFIX rdf: <http://www.w3.org/1999/02/22-rdf-syntax-ns#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
PREFIX my: <http://www.semanticweb.org/ss_sa/ontologies/2021/4/untitled-ontology-3#>

SELECT distinct ?patient ?behaviors ?riskFactor ?susceptibility WHERE {
  ?patient owl:sameAs my:subject_10019 .
  ?patient my:behaviors ?behaviors .
  ?behaviors rdf:type my:NonPreventiveBehavior .
  ?behaviors my:riskFactors ?riskFactor .
  ?behaviors my:susceptibilities ?susceptibility
}

```

?patient	?behaviors	?riskFactor	?susceptibility
my:subject_10019	my:Excessive_Alcohol_Consumption	my:Alcohol_Consumption	my:High_Liver_Cancer_Susceptibility

Figura 13. Resultado da consulta das DCNTs suscetíveis a um paciente.

```

Snap SPARQL Query:
PREFIX owl: <http://www.w3.org/2002/07/owl#>
PREFIX rdf: <http://www.w3.org/1999/02/22-rdf-syntax-ns#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
PREFIX my: <http://www.semanticweb.org/ss_sa/ontologies/2021/4/untitled-ontology-3#>

SELECT distinct ?patient ?behaviors ?riskFactor ?susceptibility WHERE {
  ?patient owl:sameAs my:subject_10132 .
  ?patient my:behaviors ?behaviors .
  ?behaviors rdf:type my:NonPreventiveBehavior .
  ?behaviors my:riskFactors ?riskFactor .
  ?behaviors my:susceptibilities ?susceptibility .
  ?susceptibility rdf:type my:PossibleHighSusceptibility
}

```

?patient	?behaviors	?riskFactor	?susceptibility
my:subject_10132	my:Low_Walking_Practice	my:Sedentarism	my:High_Heart_Failure_Susceptibility

Figura 14. Resultado da consulta dos comportamentos que aumentam a probabilidade de uma DCNT.

Snap SPARQL Query: ⏏ ⏏ ⏏

```

PREFIX owl: <http://www.w3.org/2002/07/owl#>
PREFIX rdf: <http://www.w3.org/1999/02/22-rdf-syntax-ns#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
PREFIX my: <http://www.semanticweb.org/ss_sa/ontologies/2021/4/untitled-ontology-3#>

SELECT distinct ?patient ?behaviors ?riskfactor WHERE {
  ?patient rdf:type my:Patient .
  ?patient my:behaviors ?behaviors .
  ?behaviors my:riskFactors ?riskfactor .
  ?riskfactor rdf:type my:Metabolic
}

```

Execute

?patient	?behaviors	?riskfactor
my:subject_41795	my:Excessive_Calories_Consumption	my:Obesity_Calories_Consumption
my:subject_44222	my:Excessive_Calories_Consumption	my:Obesity_Calories_Consumption
my:subject_42231	my:Excessive_Calories_Consumption	my:Obesity_Calories_Consumption
my:subject_10124	my:Excessive_Calories_Consumption	my:Obesity_Calories_Consumption

**Figura 15. Resultado da consulta do risco metabólico.**

Snap SPARQL Query: ⏏ ⏏ ⏏

```

PREFIX owl: <http://www.w3.org/2002/07/owl#>
PREFIX rdf: <http://www.w3.org/1999/02/22-rdf-syntax-ns#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
PREFIX my: <http://www.semanticweb.org/ss_sa/ontologies/2021/4/untitled-ontology-3#>

SELECT distinct ?patient ?behaviors ?riskfactor WHERE {
  ?patient rdf:type my:Patient .
  ?patient my:behaviors ?behaviors .
  ?behaviors my:riskFactors ?riskfactor .
  ?riskfactor rdf:type my:ModifiableBehavioral
}

```

Execute

?patient	?behaviors	?riskfactor
my:subject_10132	my:Low_Walking_Practice	my:Sedentarism
my:subject_10076	my:Frequent_Cigarette_Consumption	my:Smoke_Intake
my:subject_41795	my:Frequent_Cigarette_Consumption	my:Smoke_Intake
my:subject_44222	my:Frequent_Cigarette_Consumption	my:Smoke_Intake
my:subject_44222	my:Low_Walking_Practice	my:Sedentarism

**Figura 16. Resultado da consulta do fator de risco do tipo comportamentos modificáveis.**

A Figura 14 apresenta o resultado para a QC3, em que a consulta foi realizada para o paciente “subject\_10132”. O comportamento de caminhar pouco está relacionado ao sedentarismo, que é um fator de risco associado à alta suscetibilidade de doenças coronárias.

A resposta para a QC4 é apresentada na Figura 15. Os resultados foram obtidos através da análise dos fatores de risco do tipo metabólico associados aos comportamentos do paciente. Essa consulta retornou 4 pacientes com fator de risco metabólico. Cada linha da Figura 15 mostra o paciente, o seu comportamento e o fator de risco associado com aquele comportamento.

A Figura 16 apresenta a busca realizada para responder a QC5. Esta busca é similar à executada para a questão 4, alterando apenas o tipo do fator de risco. É possível ver na Figura 16 que o retorno da busca apresenta 4 pacientes com comportamentos associados a fatores de risco de comportamento modificável. Cada linha é composta por um paciente, o seu comportamento e o fator de risco associado com aquele comportamento, sendo que o paciente “subject\_44222” possui 2 comportamentos associados aos fatores de risco de comportamento modificável.

Snap SPARQL Query

```

PREFIX owl: <http://www.w3.org/2002/07/owl#>
PREFIX rdf: <http://www.w3.org/1999/02/22-rdf-syntax-ns#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
PREFIX my: <http://www.semanticweb.org/ss_sa/ontologies/2021/4/untitled-ontology-3#>

SELECT distinct ?patient ?profile ?recommendation WHERE {
  ?patient my:profile ?profile .
  ?profile my:recommendations ?recommendation .
}

```

Execute

?patient	?profile	?recommendation
my:subject_10019	my:Alcohol_Profile	my:Alcohol_Consumption_Once_A_Week
my:subject_10076	my:Cigarette_Smoke_Profile	my:Stop_Cigarette_Consumption
my:subject_10124	my:Obesity_Profile	my:2500_Calories_Daily
my:subject_41795	my:Obesity_Profile	my:2500_Calories_Daily
my:subject_41795	my:Cigarette_Smoke_Profile	my:Stop_Cigarette_Consumption
my:subject_42231	my:Obesity_Profile	my:2500_Calories_Daily
my:subject_44222	my:Obesity_Profile	my:2500_Calories_Daily
my:subject_44222	my:Cigarette_Smoke_Profile	my:Stop_Cigarette_Consumption

**Figura 17. Resultado da consulta do comportamento preventivo.**

A Figura 17 apresenta o resultado da consulta utilizada para responder a QC6. O resultado trouxe 6 pacientes que tinham recomendações de comportamentos preventivos. Cada linha apresenta o paciente, o perfil atribuído e a recomendação de comportamento. Além disso, os pacientes “subject\_44222” e “subject\_41795” estavam associados a dois perfis e com recomendações distintas.

A resposta para a QC7 é realizada com uma busca composta de duas etapas e em diferentes períodos de tempo, pois é necessário reavaliar a mudança de comportamento. A primeira etapa dessa resposta é provida na QC3, a qual permite identificar os comportamentos que aumentam a probabilidade de desenvolver uma DCNT. A segunda etapa é provida pela QC6, que fornece as recomendações de comportamentos preventivos ofertados ao usuário. Portanto, para saber quais recomendações geraram uma mudança de comportamento do usuário, é necessário executar essa busca em duas etapas conforme o decorrer do tempo para identificar a similaridade entre os comportamentos do usuário e as recomendações realizadas.

Além dos testes realizados utilizando o *dataset* MIMIC-III, a ontologia proposta foi utilizada como base de conhecimento para uma aplicação de assistência a pacientes com DCNTs chamada B-Track. Para isso, foi gerado um arquivo OWL com as regras de inferências, as quais foram importadas na aplicação para que analisassem os comportamentos, permitindo testar a viabilidade da ontologia no cotidiano dos usuários. A Figura 18 apresenta a implementação de um serviço que executa uma consulta dentro da B-Track Onto. A linha 16 apresenta o método *GetBTrackOntoRiskFactorDataByBehaviour*, que recebe por parâmetro uma *string* que informa um comportamento do usuário. Entre as linhas 18 e 31 é montada a busca na ontologia, sendo o resultado armazenado na variável *queryString*. Após a montagem da busca, as linhas 33 e 34 montam o *parser*, que traduz a busca, sendo passado como parâmetro para a ontologia no método *ExecuteQuery* na linha 36. Como resultado, é devolvido um objeto contendo o comportamento, o Fator de Risco inferido, o Perfil e a Susceptibilidade do desenvolvimento de uma DCNT (linhas 37 a 52).

```

16 4 references
17 public List<BTrackOntoRiskFactorData> GetBTrackOntoRiskFactorDataByBehaviour(string behavior)
18 {
19     SparqlParameterizedString queryString = new SparqlParameterizedString();
20     queryString.Namespaces.AddNamespace("owl", new Uri("http://www.w3.org/2002/07/owl#"));
21     queryString.Namespaces.AddNamespace("rdf", new Uri("http://www.w3.org/1999/02/22-rdf-syntax-ns#"));
22     queryString.Namespaces.AddNamespace("rdfs", new Uri("http://www.w3.org/2000/01/rdf-schema#"));
23     queryString.Namespaces.AddNamespace("my", new Uri("http://www.semanticweb.org/ss_sa/ontologies/2021/4/untitled-ontology-3#"));
24
25     queryString.CommandText = @"SELECT distinct ?profile ?riskfactor ?susceptibility WHERE {{
26         ?profile my:aimsToTreatRiskFactor ?riskfactor .
27         ?profile my:aimsToTreatSusceptibilities ?susceptibilityEntity .
28         my:{behavior} my:riskFactors ?riskfactor .
29         ?susceptibilityEntity rdf:type ?susceptibility .
30         FILTER(?susceptibility != my:Susceptibility && ?susceptibility != owl:Thing && ?susceptibility != owl:NamedIndividual)
31     }}";
32
33     SparqlQueryParser parser = new SparqlQueryParser();
34     SparqlQuery query = parser.ParseFromString(queryString);
35
36     var r = (SparqlResultSet)graph.ExecuteQuery(query);
37     var results = r.Results;
38
39     var bTrackOntoRiskFactorData = new List<BTrackOntoRiskFactorData>();
40
41     foreach ( var item in results )
42     {
43         bTrackOntoRiskFactorData.Add(new BTrackOntoRiskFactorData
44         {
45             Behavior = behavior,
46             RiskFactor = item["riskfactor"].ToString().Split("#")[1],
47             ProfileName = item["profile"].ToString().Split("#")[1],
48             Susceptibility = item["susceptibility"].ToString().Split("#")[1],
49         });
50     }
51
52     return bTrackOntoRiskFactorData;
53 }
54
55

```

Figura 18. Serviço implementado em C# para executar a consulta na B-Track Onto.

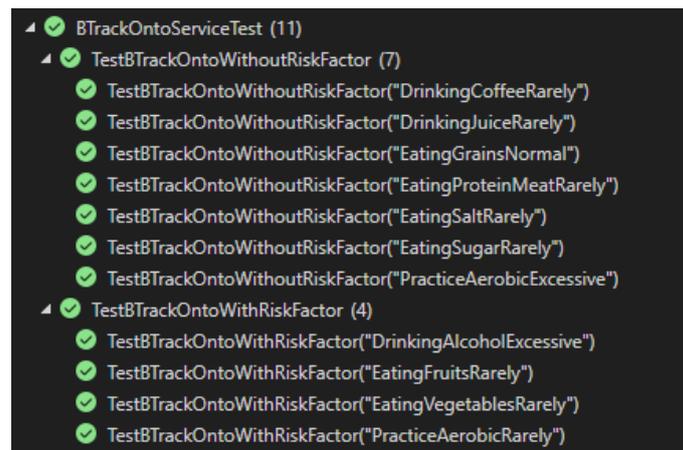


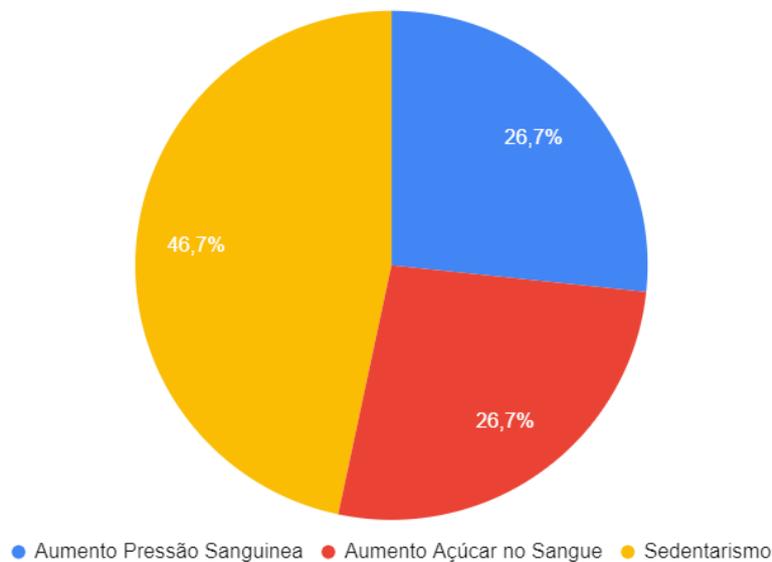
Figura 19. Testes unitários do serviço implementado da B-Track Onto.

Para testar a inferência do serviço implementado da ontologia, foram definidos testes unitários que pudessem validar o retorno ao informar um comportamento que possa estar associado ou não com doenças crônicas. Para estes testes foram selecionados alguns comportamentos que a ontologia deveria conhecer, os quais teriam ou não associação com fatores de risco. O objetivo do teste unitário consiste na confirmação da funcionalidade por amostragem, não contemplando todos os comportamentos disponíveis na ontologia. A Figura 19 apresenta os comportamentos informados a dois testes unitários. O primeiro esperava comportamentos sem associação a Fatores de Risco (*TestBTrackOntoWithoutRiskFactor*) e o segundo esperava comportamentos associados a Fatores de Risco (*TestB-*

*TrackOntoWithRiskFactor*). Os resultados dos testes unitários foram positivos, pois com base na ontologia foram inferidos corretamente quais comportamentos possuíam fatores de risco associados e quais não possuíam.

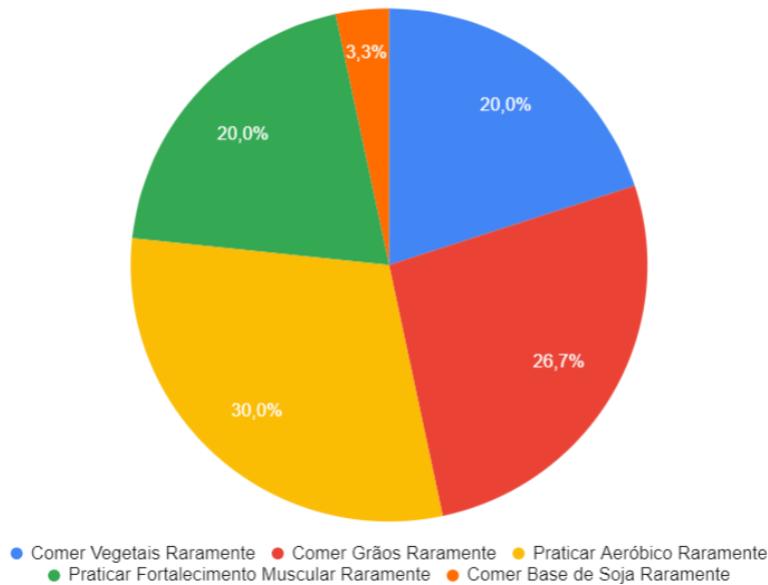
Após esses testes, foram selecionados pacientes com algum tipo de doença crônica e que tinham um *smartphone* Android para execução do assistente B-Track, que utiliza a ontologia descrita neste artigo. O experimento ocorreu no período de Setembro a Dezembro de 2023, durante 4 semanas, com 10 pacientes, tendo o intuito de validar a inferência dos seus hábitos pela ontologia. Os pacientes instalaram em seus dispositivos o assistente B-Track e, ao se cadastrarem e aceitarem o Termo de Consentimento Livre e Esclarecido (TCLE), informaram seus hábitos diários, os quais foram utilizados pela ontologia no processo de inferência, identificando quais estavam associados com fatores de risco. Todos os dados dos pacientes foram anonimizados, sendo os dados coletados associados a um Identificador Único Global (GUID) e os dados sensíveis, como e-mail e nome, foram criptografados usando o algoritmo Padrão de Criptografia Avançado (AES), garantindo a proteção da sua identidade. A Seção 7 apresenta detalhes éticos que envolveram o experimento descrito.

A Figura 20 apresenta os três fatores de risco que mais foram inferidos durante o experimento. O sedentarismo foi o fator de risco com maior prevalência, seguido pelo aumento de pressão sanguínea e aumento de açúcar no sangue. Um fator de risco pode estar associado a várias doenças crônicas em diferentes níveis de susceptibilidade.

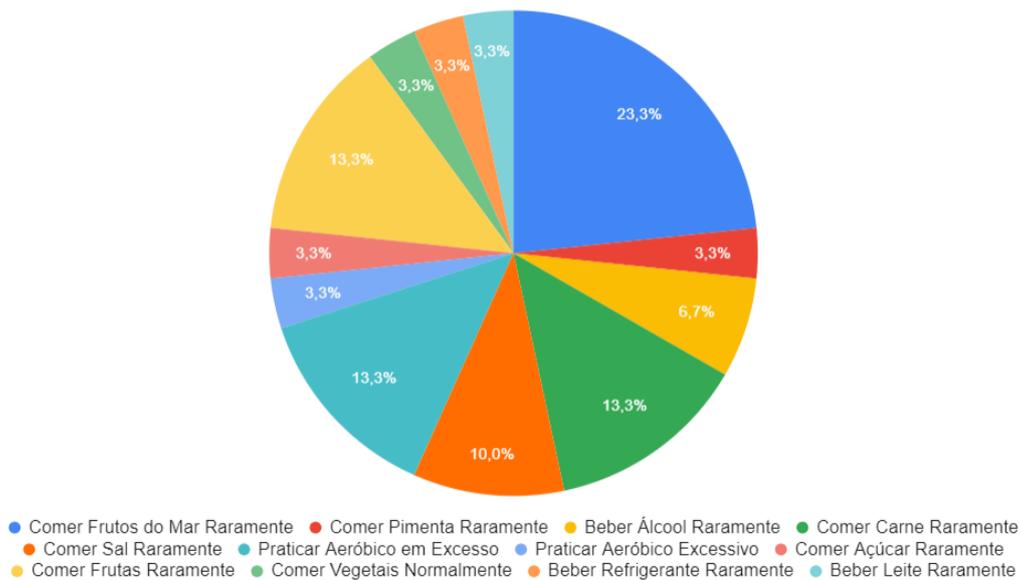


**Figura 20. Fatores de risco inferidos pela B-Track Onto.**

A Figura 21 apresenta os hábitos não preventivos inferidos pela ontologia durante o experimento. Os 3 hábitos que se destacaram foram praticar atividades aeróbicas raramente, comer grãos raramente e comer vegetais raramente.



**Figura 21. Hábitos não preventivos inferidos pela B-Track Onto.**



**Figura 22. Hábitos preventivos inferidos pela B-Track Onto.**

A Figura 22 apresenta os hábitos preventivos inferidos pela ontologia durante o experimento. Os 3 hábitos que se destacaram foram comer frutos do mar raramente, comer carne raramente e praticar atividades aeróbicas em excesso. A Tabela 4 apresenta os usuários e os 3 hábitos não preventivos e preventivos que mais ocorreram. Um ponto relevante de análise da ontologia é que um hábito é definido como não preventivo quando existe ao menos um fator de risco associado ao comportamento e preventivo quando não existem fatores de risco associados.

**Tabela 4. Comportamentos por usuários**

Usuários	Top 3 comportamentos não preventivos	Top 3 comportamentos preventivos
Usuário 1	Comer Vegetais Raramente Comer Grãos Raramente Praticar Aeróbico Raramente	Comer Frutos do Mar Raramente Comer Pimenta Raramente Beber Álcool Raramente
Usuário 2	Praticar Aeróbico Raramente Comer Grãos Raramente Praticar Fortalecimento Muscular Raramente	Comer Carne Raramente Comer Frutos do Mar Raramente Comer Sal Raramente
Usuário 3	Praticar Aeróbico Raramente Praticar Fortalecimento Muscular Raramente Comer Vegetais Raramente	Praticar Aeróbico em Excesso Comer Frutos do Mar Raramente Comer Sal Raramente
Usuário 4	Praticar Aeróbico Raramente Praticar Fortalecimento Muscular Raramente Comer Grãos Raramente	Praticar Aeróbico Excessivo Comer Frutos do Mar Raramente Comer Açúcar Raramente
Usuário 5	Praticar Aeróbico Raramente Comer Vegetais Raramente Comer Grãos Raramente	Praticar Aeróbico em Excesso Comer Frutas Raramente Comer Carne Raramente
Usuário 6	Praticar Aeróbico Raramente Praticar Fortalecimento Muscular Raramente Comer Vegetais Raramente	Praticar Aeróbico em Excesso Comer Frutas Raramente Comer Carne Raramente
Usuário 7	Comer Vegetais Raramente Comer Grãos Raramente Comer Base de Soja Raramente	Comer Frutas Raramente Comer Frutos do Mar Raramente Comer Sal Raramente
Usuário 8	Praticar Aeróbico Raramente Praticar Fortalecimento Muscular Raramente Comer Grãos Raramente	Comer Vegetais Normalmente Beber Álcool Raramente Comer Frutos do Mar Raramente
Usuário 9	Praticar Aeróbico Raramente Comer Grãos Raramente Comer Vegetais Raramente	Comer Frutos do Mar Raramente Beber Refrigerante Raramente Beber Leite Raramente
Usuário 10	Praticar Aeróbico Raramente Praticar Fortalecimento Muscular Raramente Comer Grãos Raramente	Praticar Aeróbico em Excesso Comer Frutas Raramente Comer Carne Raramente

## 7. Declaração de Ética

A presente pesquisa atende à Resolução 510/2016 do Ministério da Saúde, que regula a pesquisa com seres humanos no Brasil. O protocolo da pesquisa foi aprovado pelo Comitê de Ética em Pesquisa da Universidade do Vale do Rio dos Sinos (CAAE 67413623.3.0000.5344, disponível na Plataforma Brasil <sup>12</sup>). Todos os participantes assi-

<sup>12</sup>[http : //plataformabrasil.saude.gov.br](http://plataformabrasil.saude.gov.br)

naram o Termo de Consentimento Livre e Esclarecido (TCLE), contendo a especificação sobre os objetivos, riscos e benefícios da pesquisa. Durante todo o estudo, os pesquisadores estiveram disponíveis para resolver dúvidas dos participantes, bem como para fornecer qualquer suporte adicional necessário.

## 8. Conclusão

Este artigo propôs uma ontologia chamada B-Track Onto para inferência de comportamentos humanos relacionados a fatores de risco para doenças crônicas. Esta ontologia foi construída para servir de modelo de conhecimento para sistemas que visam acompanhar os hábitos comportamentais dos pacientes. Esses comportamentos podem estar associados aos fatores de risco de DCNTs, permitindo a realização de inferências e a representação de entidades no modelo.

A avaliação foi realizada através de questões de competência, conforme proposto na metodologia de Grüninger e Fox [1995]. Através do processo de um *reasoner*, os axiomas e propriedades de objeto definidos permitiram a realização de inferências previstas na metodologia para classificar as instâncias de forma automática nas classes definidas. A B-Track Onto permitiu identificar os comportamentos dos pacientes, bem como foi possível realizar consultas em sua base de instâncias provenientes de um *dataset* laboratorial. Além disso, a B-Track Onto também foi avaliada com dados coletados de pacientes reais por um período de 4 semanas, onde validou-se a capacidade da ontologia de inferir hábitos preventivos e não preventivos para esses pacientes.

A principal contribuição científica deste trabalho consiste na especificação de uma ontologia para inferir quais são os comportamentos dos pacientes que estão relacionados com os fatores de risco associados às DCNTs. Como contribuição social pode-se salientar o desenvolvimento de um novo recurso de base de conhecimento para utilização dentro de sistemas da área de cuidados de doenças crônicas, colaborando com o desenvolvimento de novas aplicações de Sistemas de Informação que podem ser utilizadas por pacientes, médicos e cuidadores.

Este estudo apresentou a utilização da B-Track Onto como uma abordagem integrando tecnologias e análise avançada de dados para correlacionar comportamento humano e fatores de risco de DCNTs. Além disso, apresentou seu potencial para a inferência de comportamentos, como uma ferramenta eficiente para classificação de comportamentos preventivos e não preventivos. Uma limitação deste estudo foi o número reduzido de dados inseridos na ontologia para realizar as inferências. Essa ontologia foi configurada como parte de um modelo de conhecimento para um Sistema de Informação chamado B-Track, que é uma plataforma de apoio à decisão no tratamento de DCNTs, podendo ser avaliada num cenário com maior quantidade de dados.

## 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.

## Referências

- [Alfaifi et al. 2018] Alfaifi, Y., Grasso, F., and Tamma, V. (2018). An ontology of psychological barriers to support behaviour change. In *Proceedings of the 2018 International Conference on Digital Health, DH '18*, page 11–15, New York, NY, USA. Association for Computing Machinery.
- [Amith et al. 2020] Amith, M., Wang, J., Xiong, G., Roberts, K., and Tao, C. (2020). A health consumer ontology of fast food information. In *2020 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, pages 1714–1719.
- [Bavaresco and Barbosa 2023] Bavaresco, R. S. and Barbosa, J. L. V. (2023). Ubiquitous computing in light of human phenotypes: foundations, challenges, and opportunities. *Journal of Ambient Intelligence and Humanized Computing*, 14(3):2341–2349.
- [Brown et al. 2016] Brown, M., Dip IST, P., Cert, P. H., van Woerden, H., Eslambolchilar, P., Jones, M., and John, A. (2016). Gamification and adherence to web-based mental health interventions: A systematic review. *JMIR Mental Health*, 3(3):3–391.
- [Büttenbender et al. 2022] Büttenbender, P. C., Neto, E. G. d. A., Heckler, W. F., and Barbosa, J. L. V. (2022). A computational model for identifying behavioral patterns in people with neuropsychiatric disorders. *IEEE Latin America Transactions*, 20(4):582–589.
- [Camboim et al. 2023] Camboim, B. D., da Rosa Tavares, J. E., Tavares, M. C., and Barbosa, J. L. V. (2023). Posture monitoring in healthcare: a systematic mapping study and taxonomy. *Medical & Biological Engineering & Computing*, 61(8):1887–1899.
- [Chatterjee et al. 2021a] Chatterjee, A., Prinz, A., Gerdes, M., and Martinez, S. (2021a). An automatic ontology-based approach to support logical representation of observable and measurable data for healthy lifestyle management: Proof-of-concept study. *J Med Internet Res*, 23(4):e24656.
- [Chatterjee et al. 2021b] Chatterjee, A., Prinz, A., Gerdes, M., and Martinez, S. (2021b). An automatic ontology-based approach to support logical representation of observable and measurable data for healthy lifestyle management: Proof-of-concept study. *J Med Internet Res*, 23(4):e24656.
- [Dalmina et al. 2022] Dalmina, L., Vianna, H. D., Dias, L. P. S., Schroeder, G. L., Francisco, R., and Barbosa, J. L. V. (2022). Gamiprom: A generic gamification model based on user profiles. *International Journal of Human–Computer Interaction*, 0(0):1–17.
- [Dias et al. 2020] Dias, L. P. S., Barbosa, J. L. V., Feijó, L. P., and Vianna, H. D. (2020). Development and testing of iaware model for ubiquitous care of patients with symptoms of stress, anxiety and depression. *Computer Methods and Programs in Biomedicine*, 187:105113.

- [Dias et al. 2022] Dias, L. P. S., Vianna, H. D., and Barbosa, J. L. V. (2022). Human behaviour data analysis and noncommunicable diseases: a systematic mapping study. *Behaviour & Information Technology*, 0(0):1–19.
- [El-Gayar et al. 2020] El-Gayar, O. F., Ambati, L. S., and Nawa, N. (2020). *Wearables, Artificial intelligence, and the Future of Healthcare*, chapter Deep Learning for Medical Decision Support Systems, pages 104–129. IGI Global.
- [Genesereth and Nilsson 1987] Genesereth, M. R. and Nilsson, N. J. (1987). *Logical Foundations of Artificial Intelligence*. Morgan Kaufmann Publishers Inc., San Francisco, CA, USA.
- [Goetz et al. 2022] Goetz, C., Bavaresco, R., Kunst, R., and Barbosa, J. (2022). Industrial intelligence in the care of workers’ mental health: A review of status and challenges. *International Journal of Industrial Ergonomics*, 87:103234.
- [Griffiths et al. 2020] Griffiths, J. C., De Vries, J., McBurney, M. I., Wopereis, S., Serttas, S., and Marsman, D. S. (2020). Measuring health promotion: translating science into policy. *European Journal of Nutrition*, 59(2):11–23.
- [Gruber 1993] Gruber, T. R. (1993). A translation approach to portable ontology specifications. *Knowl. Acquis.*, 5(2):199–220.
- [Grüninger and Fox 1995] Grüninger, M. and Fox, M. S. (1995). Methodology for the design and evaluation of ontologies. Available in: <http://www.eil.utoronto.ca/wp-content/uploads/enterprise-modelling/papers/gruninger-ijcai95.pdf>, access: Oct 18 2023.
- [Guermah et al. 2018] Guermah, H., Fissaa, T., Guermah, B., Hafiddi, H., and Nassar, M. (2018). Using context ontology and linear svm for chronic kidney disease prediction. In *Proceedings of the International Conference on Learning and Optimization Algorithms: Theory and Applications*, LOPAL ’18, New York, NY, USA. Association for Computing Machinery.
- [GUIMARAES 2003] GUIMARAES, F. J. Z. (2003). Ontologies use in b2c domain. Available in: <https://www.maxwell.vrac.puc-rio.br/3897/38975.PDF>, access: Jan 10 2024.
- [Heckler et al. 2022] Heckler, W. F., de Carvalho, J. V., and Barbosa, J. L. V. (2022). Machine learning for suicidal ideation identification: A systematic literature review. *Computers in Human Behavior*, 128:107095.
- [Heckler et al. 2023] Heckler, W. F., Feijó, L. P., de Carvalho, J. V., and Barbosa, J. L. V. (2023). Thoth: An intelligent model for assisting individuals with suicidal ideation. *Expert Systems with Applications*, 233:120918.
- [Hu and Kerschberg 2018] Hu, H. and Kerschberg, L. (2018). Evolving medical ontologies based on causal inference. In *Proceedings of the 2018 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining*, ASONAM ’18, page 954–957. IEEE Press.

- [Johnson et al. 2016] Johnson, A. E., Pollard, T. J., Shen, L., Lehman, L.-w. H., Feng, M., Ghassemi, M., Moody, B., Szolovits, P., Anthony Celi, L., and Mark, R. G. (2016). Mimic-iii, a freely accessible critical care database. *Scientific Data*, 3(1):160035.
- [Krummenacher and Strang 2007] Krummenacher, R. and Strang, T. (2007). Ontology-based context modeling. *3rd Workshop on Context Awareness for Proactive Systems*.
- [Kyada and Baria 2019] Kyada, D. S. and Baria, D. H. (2019). Prevalence of risk factors of non-communicable diseases among the health care professionals of a tertiary care hospital of south gujarat, india. *World Journal of Advance Healthcare Research*, 3(4):57–61.
- [Larentis et al. 2023] Larentis, A. V., Barbosa, D. N. F., and Barbosa, J. L. V. (2023). Salus: A model for educational assistance in noncommunicable chronic diseases. *IEEE Latin America Transactions*, 21(3):360–366.
- [Mamdani and Assilian 1975] Mamdani, E. and Assilian, S. (1975). An experiment in linguistic synthesis with a fuzzy logic controller. *International Journal of Man-Machine Studies*, 7(1):1–13.
- [Milne-Ives et al. 2020a] Milne-Ives, M., Lam, C., De Cock, C., Van Velthoven, M. H., and Meinert, E. (2020a). Mobile apps for health behavior change in physical activity, diet, drug and alcohol use, and mental health: Systematic review. *JMIR Mhealth Uhealth*, 8(3):e17046.
- [Milne-Ives et al. 2020b] Milne-Ives, M., Lam, C., De Cock, C., Van Velthoven, M. H., and Meinert, E. (2020b). Mobile apps for health behavior change in physical activity, diet, drug and alcohol use, and mental health: Systematic review. *JMIR Mhealth Uhealth*, 8(3):e17046.
- [Mitsis et al. 2019] Mitsis, K., Zarkogianni, K., Bountouni, N., Athanasiou, M., and Nikita, K. S. (2019). An ontology-based serious game design for the development of nutrition and food literacy skills. In *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 1405–1408.
- [Monteiro et al. 2018] Monteiro, L. Z., Varela, A. R., Alves, L. R., Santos, M. R. S., Lopes, G. R., Caetano Júnior, M. A., and Leandro, S. S. (2018). Prevalência e fatores associados ao uso de álcool e tabaco em universitários do curso de enfermagem. *Revista Eletrônica de Enfermagem*, 20.
- [Musen and Team 2015] Musen, M. A. and Team, P. (2015). The protégé project: A look back and a look forward. *AI matters*, 1(4):4–12.
- [Nagaraj and Deepalakshmi 2022] Nagaraj, P. and Deepalakshmi, P. (2022). An intelligent fuzzy inference rule-based expert recommendation system for predictive diabetes diagnosis. *International Journal of Imaging Systems and Technology*.
- [Nasiri and Khosravani 2020a] Nasiri, S. and Khosravani, M. R. (2020a). Progress and challenges in fabrication of wearable sensors for health monitoring. *Sensors and Actuators A: Physical*, 312:112105.

- [Nasiri and Khosravani 2020b] Nasiri, S. and Khosravani, M. R. (2020b). Progress and challenges in fabrication of wearable sensors for health monitoring. *Sensors and Actuators A: Physical*, 312:112105.
- [Paula et al. 2022a] Paula, L. d. S., Barbosa, J. L. V., and Dias, L. P. S. (2022a). A model for assisting in the treatment of anxiety disorder. *Universal Access in the Information Society*, 21(2):533–543.
- [Paula et al. 2022b] Paula, L. d. S., Dias, L. P. S., Francisco, R., and Barbosa, J. L. V. (2022b). Analysing iot data for anxiety and stress monitoring: A systematic mapping study and taxonomy. *International Journal of Human–Computer Interaction*, 0(0):1–21.
- [Pereira and Baranauskas 2017] Pereira, R. and Baranauskas, M. C. (2017). *Systemic and Socially Aware Perspective for Information Systems*, chapter Grand Research Challenges in IS in Brazil, pages 148–160. (Org.). I GranDSI-BR.
- [Petersen et al. 2008] Petersen, K., Feldt, R., Mujtaba, S., and Mattsson, M. (2008). Systematic mapping studies in software engineering. In *Proceedings of the 12th International Conference on Evaluation and Assessment in Software Engineering*, EASE '08, pages 68–77, Swinton, UK. British Computer Society.
- [Pfeiffer Salomão Dias et al. 2023] Pfeiffer Salomão Dias, L., Damasceno Vianna, H., Heckler, W., and Luis Victória Barbosa, J. (2023). Ontology-based reasoning to classify behaviors associated with chronic disease risk factors. In *Proceedings of the XIX Brazilian Symposium on Information Systems*, SBSI '23, page 292–299, New York, NY, USA. Association for Computing Machinery.
- [Reda et al. 2018] Reda, R., Piccinini, F., and Carbonaro, A. (2018). Towards consistent data representation in the iot healthcare landscape. In *Proceedings of the 2018 International Conference on Digital Health*, DH '18, page 5–10, New York, NY, USA. Association for Computing Machinery.
- [Rehackova et al. 2020] Rehackova, L., Araújo-Soares, V., Steven, S., Adamson, A. J., Taylor, R., and Sniehotta, F. F. (2020). Behaviour change during dietary type 2 diabetes remission: a longitudinal qualitative evaluation of an intervention using a very low energy diet. *Diabetic Medicine*, 37(6):953–962.
- [Rentz et al. 2023] Rentz, D. M., Heckler, W. F., and Barbosa, J. L. V. (2023). A computational model for assisting individuals with suicidal ideation based on context histories. *Universal Access in the Information Society*.
- [Sasseville et al. 2021] Sasseville, M., LeBlanc, A., Boucher, M., Dugas, M., Mbemba, G., Tchuente, J., Chouinard, M.-C., Beaulieu, M., Beaudet, N., Skidmore, B., Cholette, P., Aspiros, C., Larouche, A., Chabot, G., and Gagnon, M.-P. (2021). Digital health interventions for the management of mental health in people with chronic diseases: a rapid review. *BMJ Open*, 11(4).
- [Tavares et al. 2023] Tavares, J. E. d. R., Ullrich, M., Roth, N., Kluge, F., Eskofier, B. M., Gaßner, H., Klucken, J., Gladow, T., Marxreiter, F., da Costa, C. A., da Rosa Righi,

- R., and Victória Barbosa, J. L. (2023). utug: An unsupervised timed up and go test for parkinson's disease. *Biomedical Signal Processing and Control*, 81:104394.
- [Weiser 1999] Weiser, M. (1999). The computer for the 21st century. *SIGMOBILE Mob. Comput. Commun. Rev.*, 3(3):3–11.
- [WHO 2020a] WHO (2020a). Global action plan for the prevention and control of noncommunicable diseases. Available in: [https://apps.who.int/iris/bitstream/handle/10665/94384/9789241506236\\_eng.pdf;jsessionid=F5229B2BCAF5AA8C2E409B0AD099E6B3?sequence=1](https://apps.who.int/iris/bitstream/handle/10665/94384/9789241506236_eng.pdf;jsessionid=F5229B2BCAF5AA8C2E409B0AD099E6B3?sequence=1), access: Jan 19 2023.
- [WHO 2020b] WHO (2020b). Who reveals leading causes of death and disability worldwide: 2000-2019. Available in: <https://www.who.int/news/item/09-12-2020-who-reveals-leading-causes-of-death-and-disability-worldwide-2000-2019>, access: Oct 18 2023.
- [WHO 2021] WHO (2021). Strengthening ncd service delivery through uhc benefit package: technical meeting report, geneva, switzerland, 14-15 july 2020. Available in: <https://www.who.int/publications/i/item/strengthening-ncd-service-delivery-through-uhc-benefit-package-technical-meeting-report-geneva-switzerland-14-15-july-2020>, access: Oct 18 2023.
- [WHO 2023a] WHO (2023a). Noncommunicable diseases. Available in: <https://www.who.int/news-room/fact-sheets/detail/noncommunicable-diseases>, access: Oct 18 2023.
- [WHO 2023b] WHO (2023b). Risk factors - noncommunicable diseases. Available in: <http://www.emro.who.int/noncommunicable-diseases/causes/index.html>, access: Oct 18 2023.
- [WHO 2017] WHO, G. W. H. O. (2017). Depression and other common mental disorders global health estimates. Licence: CC BY-NC-SA 3.0 IGO.