

# Cuidado Ubíquo de Pacientes com Doenças Crônicas Através de um Modelo de Análise do Comportamento Humano

Lucas Pfeiffer Salomão Dias\*

L.P.S. Dias\*

lucaspfsd@gmail.com

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

Jorge Luis Victória Barbosa

J.L.V. Barbosa

jbarbosa@unisinis.br

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

## ABSTRACT

Chronic diseases are among 7 out of the 10 leading causes of death worldwide. The main chronic diseases are heart disease, cancer, chronic respiratory diseases, and diabetes. Heart disease alone causes 9 million deaths a year. Lifestyle changes can prevent many chronic diseases' deaths and their risk factors. In addition, machine learning and wearable devices have been used for behavior analysis. Therefore, this research proposes B-Track, a computational model for assistance in chronic diseases care through the analysis of behaviors that attenuate or worsen the risk factors associated with chronic diseases, working with user behavior profiles and recommendations for healthier behaviors. The B-Track collects data from different data sources for current and future human behavior analysis through the usage of data fusion and machine learning models. These data comprise the patients' context histories, which include sensor data and data from self-management surveys. The scientific contribution of B-Track model is the analysis of human behaviors directly associated with risk factors and their susceptibility to the development of NCDs. The model was evaluated through a prototype, which was used within 10 patients during your treatment. Three patients achieved changes in some behaviors over an extended period. Overall, according to the TAM Model evaluation, 83% of users agreed that B-Track was useful, and 80% found it easy to use.

## KEYWORDS

Classificação de Comportamento; 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 [33]. 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 [31].

\*Both authors contributed equally to this research.

Comportamentos como consumo de tabaco, falta de atividade física, pressão arterial elevada e sobrepeso estão entre os principais fatores de risco associados às DCNTs [26, 33]. Sendo assim, 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 [11, 33]. Dessa forma, compreender o comportamento humano associado ao modo de viver é relevante para promover hábitos saudáveis [8, 25].

A tecnologia pode ser usada como instrumento para auxílio à previsão do comportamento humano [28] e também dos principais eventos que promovem resultados para melhorias no estilo de vida, principalmente facilitando a adoção de hábitos saudáveis [15, 34]. A variedade de sensores móveis e vestíveis aumentou e ganhou destaque na computação ubíqua [1, 14, 30]. 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 [6, 9, 18, 29]. 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 [7, 16, 19].

Este artigo propõe o B-Track, um modelo computacional para assistência no cuidado de DCNTs por meio da análise de comportamentos associados aos fatores de risco de doenças crônicas. A contribuição científica do modelo B-Track é a análise dos comportamentos humanos diretamente associados aos fatores de risco e sua suscetibilidade ao desenvolvimento de DCNTs.

O texto está organizado em seis seções. A Seção 2 revisa os trabalhos relacionados que desenvolveram modelos relacionadas a DCNTs e ao comportamento humano. A seção 3 apresenta o modelo B-Track, sua arquitetura e ontologia. Os aspectos de avaliação e os resultados são abordados na seção 4. A Seção 5 apresenta as questões éticas envolvendo a avaliação do modelo e por fim na seção 6, são apresentadas as conclusões e trabalhos futuros.

## 2 TRABALHOS RELACIONADOS

Este artigo revisou trabalhos da literatura que tinham por objetivo desenvolver modelos 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 2.1.

### 2.1 Metodologia

Os trabalhos relacionados foram obtidos através de um mapeamento sistemático [7]. Este mapeamento seguiu a metodologia de Petersen et al. [21] a qual executa 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 realizou a identificação dos principais termos da área de estudo e seus sinônimos mais relevantes. Este estudo define os termos principais como *Behavior*, *Noncommunicable Diseases* e *Data Analysis*. 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 [33]. Finalmente, os sinônimos para o termo "*Data Analysis*" abrangem tópicos relacionados à ciência de dados. 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" OR "chronic diseases" OR "risk factors" OR "chronic conditions" OR diabetes OR cancer OR "cardiovascular diseases" OR "respiratory diseases" OR depression)
Noncommunicable Diseases	AND ("data analysis" OR "data analytics" OR "statistical learning" OR "machine learning" OR "deep learning" OR "data mining")
Data Analysis	

Depois de construir a *string* de busca, a próxima etapa selecionou as bases de pesquisa para consulta de artigos. Este estudo considerou as seguintes bases: PsycArticles, PsycInfo, PubMed Central, Biblioteca Digital ACM, Biblioteca Digital IEEE Xplore, Science Direct, Biblioteca Springer e Wiley.

A etapa de coleta de resultados obteve 41 trabalhos, mas apenas oito artigos estão relacionados à mesma área de estudo desta pesquisa. Estes trabalhos propuseram modelos para a análise de comportamentos relacionados a hábitos alimentares e atividades físicas, para o tratamento e acompanhamento de indivíduos com DCNTs.

## 2.2 Descrição dos Trabalhos relacionados

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

Bohanec et al. [3] desenvolveu um sistema de apoio à decisão chamado HeartMan. Este sistema serve como suporte ao paciente para auxiliar no tratamento, como gerenciamento de medicamentos, exercícios, nutrição e automonitoramento.

Meegahapola et al. [13] estudou o nível de consumo alimentar de 84 estudantes universitários no México por meio do uso de sensores de *smartphones* e autorrelatos passivos. Este estudo encontrou relação entre consumo alimentar e fatores de sociabilidade, tipos e níveis de atividades.

Krzyzanowski et al. [12] desenvolveu um sistema para monitorar a atividade física e a ingestão de frutas e vegetais chamado Rams Have Heart para apoiar um curso de intervenção em doenças cardiovasculares.

Pérez-Rodríguez et al. [20] propôs uma nova metodologia para analisar rotinas e recursos comportamentais por contexto para

detectar depressão em estudantes universitários. Por meio de interações sociais, a metodologia identifica e interpreta o comportamento, as percepções e as apreciações dos pacientes e parentes próximos sobre uma condição de saúde.

Ismail et al. [10] propôs um modelo de saúde baseado em redes neurais convolucionais para analisar fatores de saúde no ambiente da Internet das Coisas (IoT). O modelo realiza a classificação dos dados, selecionando primeiro os fatores mais importantes relacionados à saúde.

Ramsingh e Bhuvanewari [24] desenvolveram um algoritmo para análise de postagens relacionadas ao diabetes em redes sociais. A classificação é realizada por meio da frequência de uso das palavras com base na pontuação de polaridade de cada frase nos dados das mídias sociais.

Chen et al. [4] propôs o Smart Web Aid para prevenção de Diabetes Tipo 2 (SWAP-DM2), um sistema baseado na web para prevenção e tratamento do diabetes. O sistema identifica hábitos propensos ao desenvolvimento de diabetes por meio de perguntas e apresenta material educativo.

Bentley et al. [2] desenvolveu um sistema chamado Health Mashups para promover mudanças de comportamento. A proposta era identificar padrões estatísticos entre dados de bem-estar e contexto em linguagem natural. O sistema coleta manualmente informações sobre agenda do usuário, atividades físicas, sono, humor e dados alimentares, entre outros.

Para todos os trabalhos selecionados foram explorados aspectos de pesquisa, a fim de analisar os seguintes critérios:

- **Doença Crônica:** este critério visa identificar quais são as doenças crônicas tratadas pelas obras;
- **Mobile:** este item tem como objetivo identificar se o usuário pode acessar em um dispositivo móvel, permitindo atendimento em tempo real e acesso rápido quando necessário;
- **Histórico de Contexto:** este critério busca determinar foram armazenadas informações de contexto do usuário ao longo do tempo para fazer inferências baseadas em contextos anteriores;
- **Perfil:** este critério visa identificar se as obras utilizam perfis para customizar a experiência do usuário [27]. Considerar a utilização de recursos que agrupem características e informações únicas do usuário;
- **Análise de Dados:** o objetivo deste critério é identificar qual técnica de análise de dados de comportamento humano o trabalho aplicou;
- **Dados Coletados:** esse critério busca determinar quais tipos de dados são coletados, como atividades físicas, hábitos alimentares e número de passos, entre outros dados que o paciente pode fornecer;
- **Modular:** este critério visa identificar se os trabalhos possuem alguma forma de extensão de módulos, podendo agregar recursos ou novas competências;
- **Base de Conhecimento:** este critério busca determinar se o trabalho contém ou não uma base de conhecimento ou ontologia;
- **Análise de Conselhos:** este critério visa identificar quais trabalhos analisam se os usuários estão praticando comportamentos recomendados.

**Tabela 2: Trabalhos Relacionados**

Artigos	DCNTs	Móvel	Histórico de Contexto	Perfil	Análise de Dados	Dados Coletados	Modular	Base de Conhecimento	Análise de Conselhos
Bohaneec et al. [3]	Insuficiência Cardíaca	Sim	Não	Sim	DEX ( <i>Decision Expert</i> )	Hábitos alimentares, atividades físicas	Não	Não	Não
Meegahapola et al. [13]	Obesidade	Sim	Não	Não	Não	Hábitos alimentares, uso de celular, atividades físicas	Não	Não	Não
Krzyzanowski et al. [12]	Obesidade	Sim	Não	Não	Não	Hábitos alimentares, atividades físicas	Não	Não	Não
Pérez-Rodríguez et al. [20]	Diabetes	Não	Não	Não	<i>Natural Language Processing, Machine Learning, Graph Mining</i>	Hábitos alimentares, atividades físicas	Sim	<i>Knowledge Graph</i>	Não
Ismail et al. [10]	Obesidade	Não	Não	Não	<i>Double-layer CNN structure</i>	Hábitos alimentares, atividades físicas	Sim	<i>CNN-Based Health Knowledge Model</i>	Não
Ramsingh and Bhuvanewari [24]	Diabetes	Não	Não	Não	<i>Hybrid NBC TFIDF, Naive Bayes, MapReduce</i>	Hábitos alimentares, atividades físicas	Sim	Não	Não
Chen et al. [4]	Diabetes	Não	Não	Não	SPSS 16.0	Hábitos alimentares, atividades físicas	Não	Não	Não
Bentley et al. [2]	Geral	Sim	Não	Não	Não	Comportamento diário, atividades físicas, hábitos alimentares	Não	Não	Não
B-Track	Geral	Sim	Sim	Sim	<i>Data Fusion</i>	Dados relacionados com comportamentos humanos	Sim	Ontologia	Sim

A Tabela 2 apresenta cada um dos critérios comparando os trabalhos relacionados e o modelo. A maioria dos trabalhos possui pelo menos um dos critérios definidos. Além disso, nenhum dos trabalhos utilizou os critérios histórico de contextos e análise de conselhos. Além disso, nenhum trabalho suportou todos os itens simultaneamente. A análise de aconselhamento tem o papel de comparar os comportamentos dos utilizadores com as recomendações feitas durante o acompanhamento dos utilizadores e analisar ao longo do tempo se houve uma mudança de comportamento resultante da recomendação feita. Esta característica está presente apenas no modelo B-Track. Em geral, os estudos focam na educação de hábitos saudáveis e acompanhando, muitos por meio de questionários e sensores disponíveis em *smartphones*.

A análise dos trabalhos relacionados revelou que a contribuição científica do modelo B-Track é a análise dos comportamentos humanos diretamente associados aos fatores de risco e sua suscetibilidade ao desenvolvimento de DCNTs.

### 3 MODELO

O B-Track é um modelo para assistência no cuidado das DCNTs por meio da análise do comportamento humano e sua relação com os fatores de risco associados às doenças.

#### 3.1 Arquitetura

A arquitetura B-Track é organizada em tipos de componentes, como módulos, agentes, aplicações e ontologias. A Figura 1 mostra o Diagrama de Componentes expandindo-se em um contêiner individual do B-Track e mostrando os componentes dentro dele.

A Figura 1 apresenta no canto superior esquerdo os módulos da *Mobile Application*. Os módulos estão listados a seguir:

- *Behavior Tips Module*: este item tem como objetivo fornecer ao usuário dicas para praticar comportamentos preventivos;
- *Account Module*: este módulo tem como objetivo identificar os usuários, permitindo-lhes acessar o sistema, visualizar e editar seus dados gerais;
- *Gamification Module*: este item busca engajar o usuário na execução das tarefas, mostra as pontuações e faz com que as interações da pontuação e os comportamentos dos usuários mudem;

- *Context Module*: este módulo tem como objetivo coletar o contexto do usuário minuto a minuto, construindo um contexto histórico que permite ao usuário entender suas atividades e hábitos;
- *Sync Module*: o objetivo deste item é enviar dados do banco de dados local para a API e recuperar dicas de comportamento e métricas do usuário, enviando-os para o BD local.

A Figura 1 apresenta no canto superior direito os módulos da *Web Application* e eles estão listados a seguir:

- *Account Module*: este módulo tem como objetivo identificar os profissionais de saúde, permitindo-lhes acessar o sistema, visualizar e editar seus dados gerais;
- *Patient Influence Analysis Module*: este item permite ao profissional de saúde compreender os hábitos de cada paciente e o impacto dos comportamentos;
- *Patient Profile Module*: este módulo tem como objetivo permitir a visualização do perfil do paciente, das DCNTs e dos fatores de risco específicos de suscetibilidade do paciente.

Finalmente, a Figura 1 apresenta os controladores da *API Application* na parte inferior central. Os controladores deste aplicativo estão listados a seguir:

- *User Controller*: este item permite que a aplicação do usuário e a aplicação administrativa gerenciem os dados pessoais dos usuários, como perfis, comportamento humano, contextos, entre outros;
- *Context Controller*: este controlador tem como objetivo ajudar o controlador do usuário e o agente de análise de comportamento a gerenciar o contexto coletado pelo usuário;
- *Influence Controller*: este item tem como objetivo permitir que a aplicação administrativa e o agente de monitoramento de influência gerenciem a influência da dica no comportamento do usuário;
- *Behavior Controller*: este controlador permite que o agente de análise de comportamento e o agente de monitoramento de influência gerenciem comportamentos humanos coletados dos usuários;



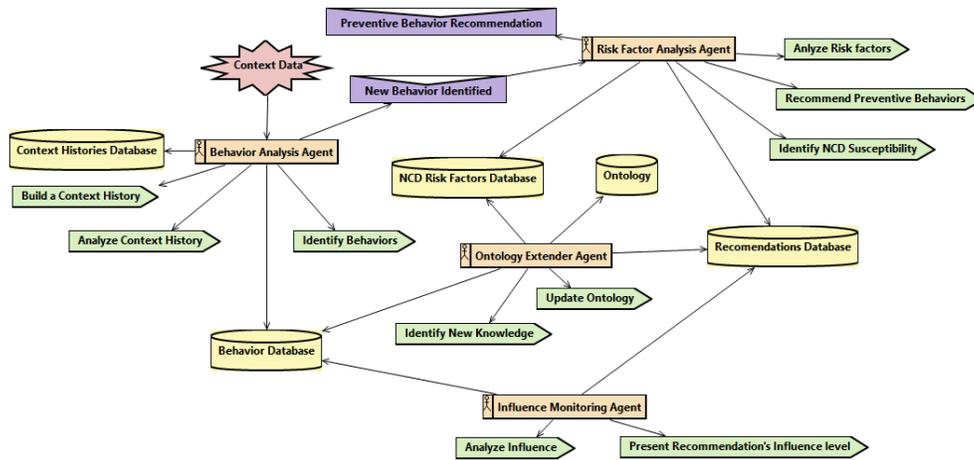


Figura 2: Visão geral dos agentes do B-Track

os dados de contexto coletados da *User Application* e constrói um histórico de contexto para cada usuário específico.

O *Módulo de Análise de Dados* possui algoritmos de aprendizado de máquina e fusão de dados, que analisam os históricos de contexto e reconhecem os comportamentos humanos neles contidos. Portanto, o *Behavior Module* identifica esses comportamentos humanos especificamente para cada usuário e envia esses dados para a *Core API*.

**3.3.2 Risk Factor Analysis Agent.** Um dos objetivos do B-Track é identificar os comportamentos dos usuários que estão associados aos fatores de risco de DCNTs, portanto esta tarefa é realizada pelo *Agente de Análise de Fatores de Risco*. A Figura 1 apresenta os módulos deste agente no canto inferior esquerdo. Ao identificar os comportamentos dos usuários, o *Risk Factor Module* deste agente realiza a análise através de inferências realizadas pela ontologia B-Track. Essas inferências identificam a relação entre os comportamentos e os fatores de risco. O *NCD Module* identifica a quais DCNTs um usuário está suscetível após a identificação dos fatores de risco. Assim, o *Preventive Behavior Module* pode recomendar comportamentos preventivos a serem realizados pelo usuário.

**3.3.3 Influence Monitoring Agent.** Além de analisar o comportamento dos usuários para identificar o risco de desenvolver uma DCNT, o modelo B-Track recomenda a prática de hábitos saudáveis, portanto o modelo verifica a influência dessas recomendações. A Figura 1 apresenta os módulos do *Influence Monitoring Agent* no canto central direito. A influência acontece comparando os comportamentos anteriores dos usuários com os novos. Assim, a expectativa é que os comportamentos não preventivos diminuam e os preventivos aumentem, indicando que o usuário está seguindo as recomendações de hábitos saudáveis.

**3.3.4 Ontology Extender Agent.** O modelo B-Track utiliza como base de conhecimento uma ontologia chamada B-Track Onto. O modelo proposto pode adquirir novos conhecimentos sobre a associação entre comportamento humano e fatores de risco. A Figura 1 apresenta os módulos do *Ontology Extender Agent* no canto inferior

direito. A abordagem utilizada por esse agente depende da curadoria de um especialista para definir os novos fatores de risco de DCNTs e associá-los aos comportamentos existentes identificados pelo modelo B-Track. A tarefa de agregar esse novo conhecimento à ontologia é de responsabilidade do *Ontology Extender Agent*.

### 3.4 B-Track Onto

A ontologia utilizada contempla as classes necessárias para reconhecer os comportamentos relacionados aos fatores de risco [22, 23], como por exemplo consumo de tabaco, sódio ou exposição ao sol, que foram mapeados pela Organização Mundial da Saúde [33].

A Figura 3 apresenta a ontologia, suas relações entre os conceitos envolvendo comportamentos humanos, fatores de risco e DCNTs. A modelagem foi realizada de forma a categorizar comportamentos, suas frequências, 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 Organização Mundial da Saúde categoriza os fatores de risco como fatores metabólicos ou modificáveis [32], 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 3 subclasses *PossibleLowSusceptibility*, *PossibleNormalSusceptibility* e *PossibleHighSusceptibility*.

A classe *NonCommunicableDisease* possui 5 subclasses a qual 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 classe *Profile* representa os perfis que reúnem pessoas com comportamentos similares e possui recomendações de comportamentos preventivos oriundas da classe *Recommendation*. O nível de influência dessa recomendação é representada pela classe *InfluenceLevel*, e

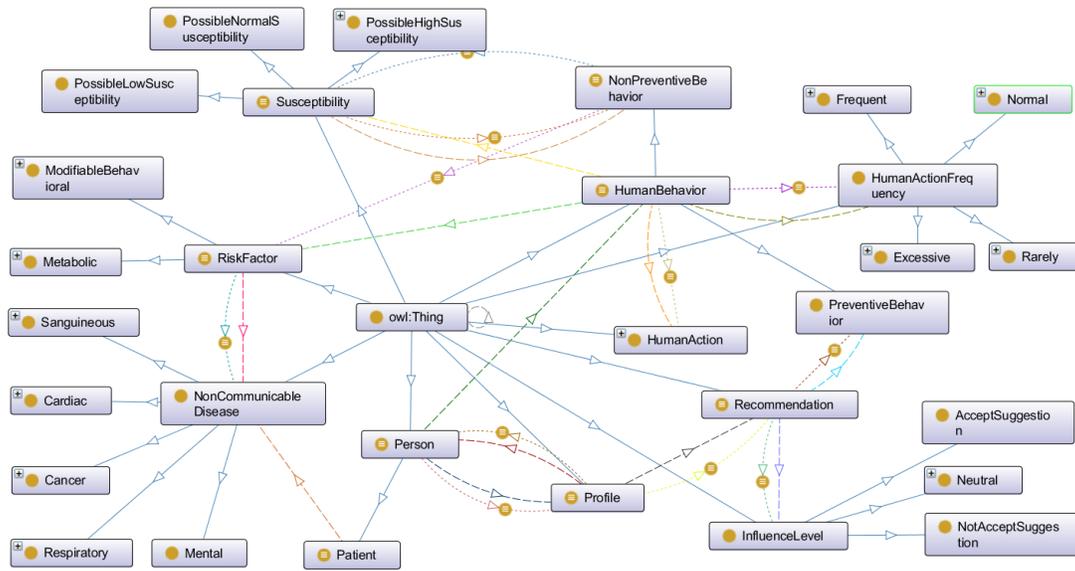


Figura 3: Visão hierárquica da B-Track Onto.

possui 3 subclasses: *AcceptSuggestion*, *Neutral* e *NotAcceptSuggestion*.

No B-Track, um comportamento humano está associado a uma ação e uma frequência. Além disso, este comportamento possui uma suscetibilidade relacionada a um fator de risco, que está relacionado com doenças crônicas. As recomendações possuem níveis de influência e estão associados 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.

#### 4 AVALIAÇÃO E RESULTADOS

Para avaliar o modelo proposto neste trabalho, foi implementado um protótipo baseado no B-Track. Após a criação do protótipo, foram selecionados 10 pacientes com alguma DCNT para utilizar o protótipo por pelo menos duas semanas. Esses pacientes utilizaram o protótipo para informar suas atividades físicas praticadas diariamente e dieta alimentar, preenchendo questionários visuais, informando quantidade e tipos de cada item. Essas informações foram utilizadas pelo protótipo para analisar comportamentos humanos e recomendar comportamentos saudáveis.

A avaliação mostrou a capacidade do modelo em analisar comportamentos, identificar comportamentos não preventivos e sugerir comportamentos benéficos à saúde. Para preservar a identidade dos pacientes que utilizaram B-Track serão identificados como P1, P2, P3, P4, P5, P6, P7, P8, P9 e P10.

##### 4.1 Hábitos dos Pacientes

O B-Track coleta hábitos dos pacientes para analisar e classificar os comportamentos que atenuam (preventivos) ou pioram (não preventivos) os fatores de risco associados às DCNTs. Usando os dados de hábitos coletados dos pacientes ao longo de uma semana,

o modelo B-Track determina se um comportamento específico é "Raramente", "Normal", "Frequente" ou "Excessivo".

Esta definição utiliza tanto a quantidade quanto a frequência de um hábito. Os hábitos alimentares são categorizados como "Nenhum", "Muito Pouco", "Pouco", "Moderado", "Alto" e "Muito Alto". Os hábitos de exercício são categorizados como "Nenhum", "Moderado" e "Forte". A frequência é definida pelo número de dias da semana de ocorrências. "Raramente" é definido como 2 ou menos ocorrências, "Normal" como 3 ou 4, "Frequente" como 5 ou 6 e "Excessivo" como 7 dias por semana. A mesma definição de frequência se aplica tanto à dieta quanto aos hábitos de exercício.

A Figura 4 apresenta os 10 principais comportamentos preventivos dos pacientes, o modelo B-Track define hábitos preventivos como aqueles que não estão associados a nenhum fator de risco. Praticar Aeróbico Excessivo foi o hábito mais preventivo com 31%, seguido por Beber Álcool Raramente e Comer Proteínas do Mar Raramente com 9%, com Comer Frituras Raramente, Comer Gordura Raramente e Comer Açúcar Raramente com 8%. Comer sal raramente, comer pimenta raramente, beber suco raramente e beber leite raramente a 7%.

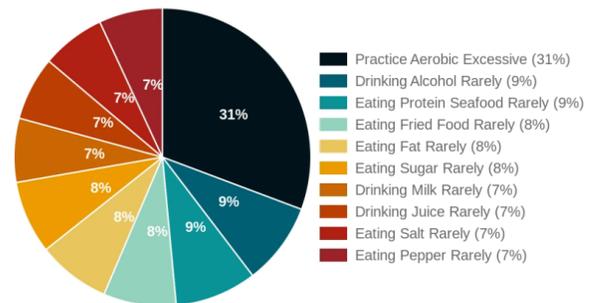


Figura 4: Comportamentos preventivos dos pacientes

O B-Track coleta hábitos dos pacientes para analisar e classificar os comportamentos que atenuam (preventivos) ou pioram (não preventivos) os fatores de risco associados às DCNTs. Usando os dados de hábitos coletados dos pacientes ao longo de uma semana, o modelo B-Track determina se um comportamento específico é "Raramente", "Normal", "Frequente" ou "Excessivo".

Esta definição utiliza tanto a quantidade quanto a frequência de um hábito. Os hábitos alimentares são categorizados como "Nenhum", "Muito Pouco", "Pouco", "Moderado", "Alto" e "Muito Alto". Os hábitos de exercício são categorizados como "Nenhum", "Moderado" e "Forte". A frequência é definida pelo número de dias da semana de ocorrências. "Raramente" é definido como 2 ou menos ocorrências, "Normal" como 3 ou 4, "Frequente" como 5 ou 6 e "Excessivo" como 7 dias por semana. A mesma definição de frequência se aplica tanto à dieta quanto aos hábitos de exercício.

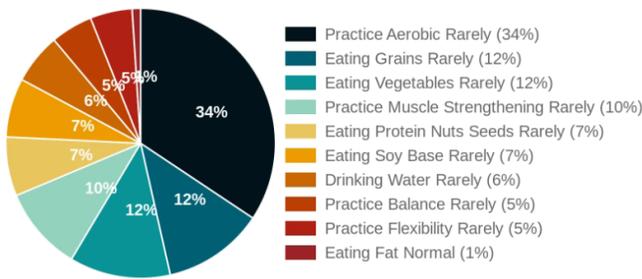


Figura 5: Comportamentos não preventivos dos pacientes

A figura 5 apresenta os 10 principais comportamentos não preventivos dos pacientes, que estão associados a fatores de risco. Praticar Aeróbico Raramente foi o hábito mais não preventivo com 34%, seguido de Comer Raramente Grãos e Comer Legumes Raramente com 12%, e Praticar Fortalecimento Muscular Raramente com 10%. Comer sementes de proteínas e nozes raramente e comer base de soja raramente em 7%, enquanto beber água raramente em 6%. Pratique o equilíbrio raramente e pratique a flexibilidade raramente em 5%. Comer Gordura Normal tem a menor representação em 1%.

Em geral, os pacientes tendem a adotar hábitos mais prejudiciais à saúde relacionados à atividade física do que à dieta alimentar. Isto pode incluir não praticar exercício suficiente, levar um estilo de vida sedentário ou não praticar atividade física regular.

#### 4.2 Doenças Crônicas Suscetíveis

O B-Track Onto infere os fatores de risco com base nos comportamentos humanos dos pacientes, permitindo a compreensão das DCNTs às quais os pacientes estão suscetíveis. A figura 6 apresenta as 9 principais DCNTs às quais os pacientes são suscetíveis com base nos fatores de risco relacionados aos seus comportamentos.

A diabetes foi a DCNT susceptível mais prevalente com 21%, seguida pela doença coronária com 20%, com demência e câncer do cólon com 15%. O AVC representa 10%, enquanto o câncer gástrico, as doenças cardiovasculares e a hipertensão representam 5% cada. A Doença Renal Crônica tem a menor representação, 2%.

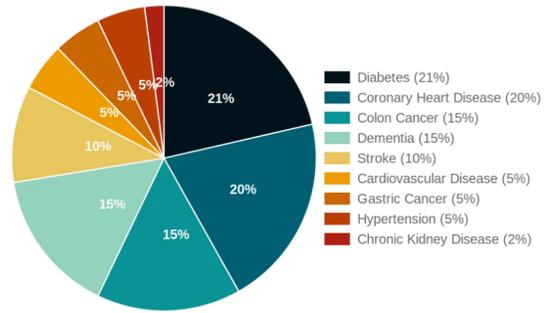


Figura 6: DCNTs suscetíveis aos pacientes

#### 4.3 Análises de Hábitos

O modelo B-Track analisa hábitos dos pacientes e os armazena gerando históricos contextuais, com ações, frequência, comportamento associado aos fatores de risco e quais DCNTs são suscetíveis. Este histórico de contexto dos usuários foi analisado para entender o impacto das recomendações nas mudanças de comportamento dos usuários.

Dos dez pacientes que participaram do experimento, nove deles haviam feito mudanças em seus hábitos pouco saudáveis em algum momento. O paciente P1 não apresentou nenhuma mudança de comportamento. Os pacientes P2, P3, P5, P7, P9 e P10 tiveram mudanças de hábitos em curto prazo, enquanto os pacientes P4, P6 e P8 tiveram mudanças em longo prazo.

A experiência sugere uma tendência para melhorias nos padrões comportamentais, mas é incerto se estas mudanças seriam eficazes a longo prazo. É necessária uma monitorização adicional dos pacientes durante um período prolongado para determinar a eficácia destas alterações.

#### 4.4 Avaliação TAM

No modelo TAM, a satisfação do usuário é medida em duas categorias: utilidade percebida e facilidade de uso percebida [5]. A utilidade percebida é utilizada para determinar se a tecnologia proposta pode ajudar o usuário a realizar uma atividade de forma mais adequada, enquanto a facilidade de uso avalia se a tecnologia pode ser utilizada com o mínimo esforço. Desta forma, o questionário de avaliação é dividido em duas categorias, uma quanto à sua utilidade e outra quanto à sua facilidade de uso. O questionário consiste em itens Likert de cinco níveis: "discordo totalmente", "discordo parcialmente", "indiferente", "concordo parcialmente" e "concordo totalmente".

Tabela 3: Itens relacionados à avaliação da utilidade

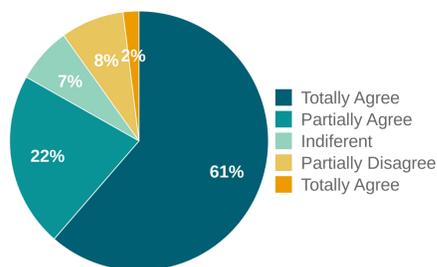
Questão	Descrição
1	O conhecimento de quais hábitos estão associados a fatores de risco é relevante.
2	As opções de atividade física são úteis para registrar hábitos de exercício físico.
3	As opções alimentares são úteis para registrar hábitos alimentares.
4	A possibilidade de reportar hábitos a qualquer momento é relevante.
5	Os hábitos saudáveis fornecidos nos materiais educativos são úteis.
6	Notificações ajudam a aumentar a conscientização sobre os hábitos diários.

Para avaliar os resultados, foi computado o percentual de seleção de cada opção ('discordo totalmente', 'discordo parcialmente', 'indiferente', 'concordo parcialmente' ou 'concordo totalmente') por questão. Nesse sentido, será calculada a média dos percentuais obtidos para cada opção de acordo com a categoria em questão (utilidade ou facilidade de uso). A média dos percentuais de cada opção será equivalente ao índice médio de satisfação avaliado pelos usuários voluntários para cada categoria.

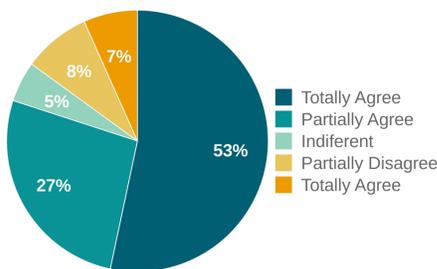
**Tabela 4: Itens relacionados à avaliação da usabilidade**

Questão	Descrição
1	Os hábitos associados aos fatores de risco são claramente apresentados.
2	As opções de atividade física são facilmente utilizadas.
3	As opções de comida são usadas sem esforço.
4	As notificações são simples de entender.
5	O material educativo pode ser consultado facilmente.
6	O número de notificações solicitando a realização de hábitos é adequado.

As respostas para cada categoria, utilidade e usabilidade, foram geralmente positivas. Os resultados das médias dos pacientes que usaram o TAM para questões relacionadas à utilidade do B-Track são apresentados na Figura 7, mostrando que 61% dos pacientes que usaram o B-Track concordam completamente que o aplicativo é útil em sua rotina de tratamento, 22% concordam parcialmente, 7% são indiferentes, 8% discordam parcialmente e 2% discordam totalmente. Em relação à usabilidade do B-Track 53% dos pacientes concordam completamente que o B-Track é fácil de usar, 27% concordam parcialmente, 5% são indiferentes, 8% discordam parcialmente e 7% discordam totalmente (Figura 8).



**Figura 7: Utilidade geral percebida pelos pacientes**



**Figura 8: Usabilidade geral percebida pelos pacientes**

Analisando o TAM é possível perceber que, em uma visão geral, o B-Track obteve uma boa avaliação de utilidade e usabilidade pelos pacientes.

## 5 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>1</sup>). Todos os participantes assinaram 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.

## 6 CONCLUSÃO

Os resultados obtidos através dos experimentos indicam que a utilização do B-Track para apoio ao tratamento das DCNTs é possível e útil ao paciente, porém, ainda é necessária uma avaliação com um grupo maior de pacientes e por um período mais longo para uma análise mais detalhada e precisa.

Os pacientes participantes do experimento apresentavam hábitos associados a fatores de risco com suscetibilidade ao desenvolvimento de DCNTs, como doença coronariana, diabetes e demência. Alguns pacientes já apresentavam doenças cardíacas, hipertensão e diabetes, onde seus hábitos poderiam piorar o quadro atual.

Através da análise do comportamento dos pacientes, foram feitas recomendações de hábitos saudáveis por meio de material educativo. Os pacientes P4, P6 e P8 obtiveram mudanças em alguns comportamentos por um período mais longo. Para o paciente P1 não foram observadas alterações e os demais pacientes tiveram alterações comportamentais por curtos períodos. O paciente P4 alterou seu consumo de vegetais e alimentos à base de soja de raro para normal, para P6 notou-se que a frequência da prática aeróbica mudou de pouco frequente para excessiva e para P8 a frequência da prática de exercícios aeróbicos mudou de raramente para normal, frequente e excessivo.

Através da avaliação do TAM foi possível perceber pontos de melhoria no B-Track, principalmente nos materiais educativos, onde 20% dos pacientes não acharam útil, na facilidade em encontrar os fatores de risco associados aos hábitos, onde 20% dos pacientes apontaram dificuldades, na usabilidade percebida pelos pacientes nas opções alimentares, onde 20% relataram dificuldades, e no número de notificações solicitando a implementação de hábitos, onde 20% não consideraram adequado.

## 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.

<sup>1</sup><http://plataformabrasil.saude.gov.br>

## REFERÊNCIAS

- [1] Rodrigo Simon Bavaresco and Jorge Luis Victória Barbosa. 2023. Ubiquitous computing in light of human phenotypes: foundations, challenges, and opportunities. *Journal of Ambient Intelligence and Humanized Computing* 14, 3 (01 Mar 2023), 2341–2349. <https://doi.org/10.1007/s12652-022-04489-2>
- [2] Frank Bentley, Konrad Tollmar, Peter Stephenson, Laura Levy, Brian Jones, Scott Robertson, Ed Price, Richard Catrambone, and Jeff Wilson. 2013. Health mashups: Presenting statistical patterns between wellbeing data and context in natural language to promote behavior change. *ACM Transactions on Computer-Human Interaction* 20, 5 (nov 2013), 27 pages. <https://doi.org/10.1145/2503823>
- [3] Marko Bohanec, Gennaro Tartarisco, Flavia Marino, Giovanni Pioggia, Paolo Emilio Puddu, Michele Salvatore Schiariti, Anneleen Baert, Sofie Pardaens, Els Clays, Aljoša Vodopija, and Mitja Luštrek. 2021. HeartMan DSS: A decision support system for self-management of congestive heart failure. *Expert Systems with Applications* 186 (2021), 115688. <https://doi.org/10.1016/j.eswa.2021.115688>
- [4] Penglai Chen, Jing Chai, Jing Cheng, Kaichun Li, Shaoyu Xie, Han Liang, Xingrong Shen, Rui Feng, and Debin Wang. 2014. A smart web aid for preventing diabetes in rural china: Preliminary findings and lessons. *Journal of Medical Internet Research* 16, 4 (2014), 0. <https://doi.org/10.2196/jmir.3228>
- [5] Fred D Davis. 1989. Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS quarterly* 1, 1 (1989), 319–340.
- [6] Lucas Pfeiffer Salomão Dias, Jorge Luis Victória Barbosa, Luan Paris Feijó, and Henrique Damasceno Vianna. 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 (2020), 105113. <https://doi.org/10.1016/j.cmpb.2019.105113>
- [7] Lucas Pfeiffer Salomão Dias, Henrique Damasceno Vianna, and Jorge Luis Victória Barbosa. 2022. Human behaviour data analysis and noncommunicable diseases: a systematic mapping study. *Behaviour & Information Technology* 0, 0 (2022), 1–19. <https://doi.org/10.1080/0144929X.2022.2128422>
- [8] James C. Griffiths, Jan De Vries, Michael I. McBurney, Suzan Wopereis, Samet Serttas, and Daniel S. Marsman. 2020. Measuring health promotion: translating science into policy. *European Journal of Nutrition* 59, 2 (01 Sep 2020), 11–23. <https://doi.org/10.1007/s00394-020-02359-1>
- [9] Weslei Felipe Heckler, Luan Paris Feijó, Juliano Varella de Carvalho, and Jorge Luis Victória Barbosa. 2023. Thoth: An intelligent model for assisting individuals with suicidal ideation. *Expert Systems with Applications* 233 (2023), 120918. <https://doi.org/10.1016/j.eswa.2023.120918>
- [10] Walaa N. Ismail, Mohammad Mehedi Hassan, Hessah A. Alsalamah, and Giancarlo Fortino. 2020. CNN-based health model for regular health factors analysis in internet-of-medical things environment. *IEEE Access* 8 (2020), 52541–52549. <https://doi.org/10.1109/ACCESS.2020.2980938>
- [11] Si Si Jia, Rebecca Raeside, Emma Sainsbury, Sara Wardak, Philayrath Phongsavan, Julie Redfern, Margaret Allman-Farinelli, Melissa A. Fernandez, Stephanie R. Partridge, and Alice A. Gibson. 2024. Use of online food retail platforms throughout the COVID-19 pandemic and associated diet-related chronic disease risk factors: A systematic review of emerging evidence. *Obesity Reviews* 25, 6 (2024), e13720. <https://doi.org/10.1111/obr.13720> arXiv:<https://onlinelibrary.wiley.com/doi/pdf/10.1111/obr.13720>
- [12] Michelle K Krzyzanowski, Paul N Kizakevich, Vanessa Duren-Winfield, Randall Eckhoff, Joel Hampton, Loneke T Blackman Carr, Georgia McCauley, Kristina B Roberson, Elijah O Onsomu, John Williams, and Amanda Alise Price. 2020. Rams Have Heart, a Mobile App Tracking Activity and Fruit and Vegetable Consumption to Support the Cardiovascular Health of College Students: Development and Usability Study. *JMIR Mhealth Uhealth* 8, 8 (5 Aug 2020), e15156. <https://doi.org/10.2196/15156>
- [13] Lakmal Meegahapola, Salvador Ruiz-Correa, Viridiana del Carmen Robledo-Valero, Emilio Ernesto Hernandez-Huerfano, Leonardo Alvarez-Rivera, Ronald Chenu-Abente, and Daniel Gatica-Perez. 2021. One More Bite? Inferring Food Consumption Level of College Students Using Smartphone Sensing and Self-Reports. *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.* 5, 1, Article 26 (March 2021), 28 pages. <https://doi.org/10.1145/3448120>
- [14] L. Mertz. 2016. Convergence Revolution Comes to Wearables: Multiple Advances are Taking Biosensor Networks to the Next Level in Health Care. *IEEE Pulse* 7, 1 (Jan 2016), 13–17. <https://doi.org/10.1109/MPUL.2015.2498475>
- [15] Madison Milne-Ives, Ching Lam, Caroline De Cock, Michelle Helena Van Velthoven, and Edward Meinert. 2020. Mobile Apps for Health Behavior Change in Physical Activity, Diet, Drug and Alcohol Use, and Mental Health: Systematic Review. *JMIR Mhealth Uhealth* 8, 3 (18 Mar 2020), e17046. <https://doi.org/10.2196/17046>
- [16] Sara Nasiri and Mohammad Reza Khosravani. 2020. Progress and challenges in fabrication of wearable sensors for health monitoring. *Sensors and Actuators A: Physical* 312 (2020), 112105. <https://doi.org/10.1016/j.sna.2020.112105>
- [17] Lin Padgham and Michael Winikoff. 2005. *Developing intelligent agent systems: A practical guide*. Vol. 13. John Wiley & Sons, UK.
- [18] Leonardo dos Santos Paula, Jorge Luis Victória Barbosa, and Lucas Pfeiffer Salomão Dias. 2022. A model for assisting in the treatment of anxiety disorder. *Universal Access in the Information Society* 21, 2 (01 Jun 2022), 533–543. <https://doi.org/10.1007/s10209-020-00786-9>
- [19] Leonardo dos Santos Paula, Lucas Pfeiffer Salomão Dias, Rosemary Francisco, and Jorge Luis Victória Barbosa. 2022. Analysing IoT Data for Anxiety and Stress Monitoring: A Systematic Mapping Study and Taxonomy. *International Journal of Human-Computer Interaction* 0, 0 (2022), 1–21. <https://doi.org/10.1080/10447318.2022.2132361>
- [20] Gael Pérez-Rodríguez, Martín Pérez-Pérez, Florentino Fdez-Riverola, and Anália Lourenço. 2020. Mining the sociome for Health Informatics: Analysis of therapeutic lifestyle adherence of diabetic patients in Twitter. *Future Generation Computer Systems* 110 (sep 2020), 214–232. <https://doi.org/10.1016/j.future.2020.04.025>
- [21] Kai Petersen, Robert Feldt, Shahid Mujtaba, and Michael Mattsson. 2008. Systematic Mapping Studies in Software Engineering. In *Proceedings of the 12th International Conference on Evaluation and Assessment in Software Engineering (EASE '08)*. British Computer Society, Swinton, UK, 68–77.
- [22] Lucas Pfeiffer Salomão Dias, Henrique Damasceno Vianna, Weslei Heckler, and Jorge Luis Victória Barbosa. 2023. Ontology-Based Reasoning to Classify Behaviors Associated with Chronic Disease Risk Factors. In *Proceedings of the XIX Brazilian Symposium on Information Systems (Maceió, Brazil) (SBSI '23)*. Association for Computing Machinery, New York, NY, USA, 292–299. <https://doi.org/10.1145/3592813.3592917>
- [23] Lucas Pfeiffer Salomão Dias, Henrique Damasceno Vianna, Weslei Heckler, and Jorge Luis Victória Barbosa. 2024. Identifying Chronic Disease Risk Behaviors: An ontology-based approach. *iSys - Brazilian Journal of Information Systems* 17, 1 (Jun. 2024), 7:1 – 7:31. <https://doi.org/10.5753/isy.2024.3762>
- [24] J. Ramsingh and V. Bhuvanawari. 2018. An efficient Map Reduce-Based Hybrid NBC-TFIDF algorithm to mine the public sentiment on diabetes mellitus – A big data approach. *Journal of King Saud University - Computer and Information Sciences* 0, 0 (2018), 0. <https://doi.org/10.1016/j.jksuci.2018.06.011>
- [25] L. Rehackova, V. Araújo-Soares, S. Steven, A. J. Adamson, R. Taylor, and F. F. Sniehotta. 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 (2020), 953–962. <https://doi.org/10.1111/dme.14066>
- [26] Carolina C Silva, Justin Presseau, Zack van Allen, Paulina M Schenk, Maiara Moreto, John Dinsmore, and Marta M Marques. 2024. Effectiveness of Interventions for Changing More Than One Behavior at a Time to Manage Chronic Conditions: A Systematic Review and Meta-analysis. *Annals of Behavioral Medicine* 58, 6 (05 2024), 432–444. <https://doi.org/10.1093/abm/kaae021> arXiv:<https://academic.oup.com/abm/article-pdf/58/6/432/57830880/kaae021.pdf>
- [27] Mona Tanwar, Sunil Kumar Khatri, and Ravi Pendse. 2022. Semantic Term-Coupling-Based Feature Enhancement of User Profiles in Recommendation Systems. *Journal of Cases on Information Technology (JCIT)* 24, 03 (2022), 1–16. <https://doi.org/10.4018/JCIT.20220701.0a1>
- [28] Jan Torpus, Cedric Julian Spindler, and Jonas Kellermeyer. 2023. Detecting Human Attitudes through Interactions with Responsive Environments. In *Proceedings of the 2023 ACM International Conference on Interactive Media Experiences (Nantes, France) (IMX '23)*. Association for Computing Machinery, New York, NY, USA, 1–13. <https://doi.org/10.1145/3573381.3596160>
- [29] Fabian Wahle, Tobias Kowatsch, Elgar Fleisch, Michael Rufer, and Steffi Weidt. 2016. Mobile Sensing and Support for People With Depression: A Pilot Trial in the Wild. *JMIR mHealth and uHealth* 4, 3 (Sep 2016), e111.
- [30] Mark Weiser. 1999. The Computer for the 21st Century. *SIGMOBILE Mob. Comput. Commun. Rev.* 3, 3 (jul 1999), 3–11. <https://doi.org/10.1145/329124.329126>
- [31] WHO. 2020. 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](https://apps.who.int/iris/bitstream/handle/10665/94384/9789241506236_eng.pdf), access: Jan 19 2023.
- [32] WHO. 2021. Risk factors - Noncommunicable diseases. Available in: <http://www.emro.who.int/noncommunicable-diseases/causes/index.html>, access: Jan 19 2023.
- [33] WHO. 2022. Noncommunicable diseases. Available in: <https://www.who.int/news-room/fact-sheets/detail/noncommunicable-diseases>, access: Jan 19 2023.
- [34] Han Zhang, Leijie Wang, Yilun Sheng, Xuhai Xu, Jennifer Mankoff, and Anind K. Dey. 2023. A Framework for Designing Fair Ubiquitous Computing Systems. In *Adjunct Proceedings of the 2023 ACM International Joint Conference on Pervasive and Ubiquitous Computing & the 2023 ACM International Symposium on Wearable Computing (Cancun, Quintana Roo, Mexico) (UbiComp/ISWC '23 Adjunct)*. Association for Computing Machinery, New York, NY, USA, 366–373. <https://doi.org/10.1145/3594739.3610677>