

e-Health | Avaliação da qualidade de vida através de informações de dispositivos vestíveis

Matheus Gabriel Ranze - 57016

Dissertação apresentada à Escola Superior de Tecnologia e de Gestão de Bragança para obtenção do Grau de Mestre em Engenharia Mecânica, no âmbito do programa de Dupla Diplomação com a Universidade Tecnológica Federal do Paraná.

Trabalho orientado por:
Prof. André Chaves Mendes
Prof. Omero Francisco Bertol

Bragança
2023-2024

e-Health | Avaliação da qualidade de vida através de informações de dispositivos vestíveis

Matheus Gabriel Ranze - 57016

Dissertação apresentada à Escola Superior de Tecnologia e de Gestão de Bragança para obtenção do Grau de Mestre em Engenharia Mecânica, no âmbito do programa de Dupla Diplomação com a Universidade Tecnológica Federal do Paraná.

Trabalho orientado por:
Prof. André Chaves Mendes
Prof. Omero Francisco Bertol

Bragança
2023-2024

Dedicatória

A Deus, que me iluminou e me deu força nos momentos mais desafiadores.

À minha família, cujo amor, apoio e sacrifício me proporcionaram a base para buscar meus sonhos.

À minha namorada, por me incentivar nesta jornada. Sua presença, compreensão e apoio foram pilares que me sustentaram e me impulsionaram nos momentos de incerteza.

Aos meus amigos, pela amizade, risadas e momentos de descontração que foram essenciais para manter o equilíbrio em minha jornada.

E a todos que, de alguma forma, estiveram ao meu lado, oferecendo palavras de incentivo e acreditando em mim.

Agradecimentos

Gostaria de expressar minha sincera gratidão a todos os que contribuíram para a realização desta dissertação de mestrado.

Primeiramente, elevo meu sincero agradecimento a Deus, fonte da minha força e inspiração, por guiar-me ao longo desta jornada e proporcionar-me a sabedoria e perseverança necessárias para alcançar este objetivo.

Minha eterna gratidão dirige-se ao meu tio, Walter Ranze Junior, que é como um pai para mim e me deu todo o suporte necessário para ultrapassar esta etapa. Esta conquista só foi possível graças a ele. À minha tia, Tatielle Carina Ranze, agradeço pelo amor, incentivo e apoio constantes, que frequentemente me motivaram em momentos difíceis. À minha avó, Cléa Lúcia Pacheco Ranze, que também considero minha mãezinha, sou grato por suas orações e amor incondicional, que sempre me guiaram nos momentos de dúvida e dificuldade. Também agradeço à minha tia, Tissiane Cristine Ranze, por sempre estar presente, mesmo à distância, transmitindo boas energias com ligações, fotos e imagens que demonstram a grandeza de seu coração e carinho.

Agradeço ao meu primo, Arthur Felipe Ranze Tarram, que caminhou ao meu lado durante esta jornada, pelas suas mensagens e imagens cômicas que proporcionaram momentos de descontração e alegria. Também sou grato ao meu avô, Walter Ranze, sempre íntegro, sábio e honesto, cuja força inabalável sempre me inspirou a ser resiliente.

Expresso minha profunda gratidão à minha querida namorada, Sthefane Arissa Harada, cuja visão e habilidade única me ajudaram a visualizar soluções que antes não tinha percebido. Seu constante incentivo foi crucial para finalizar essa fase acadêmica com sucesso.

Aos meus amigos, que foram essenciais em momentos de dificuldade, proporcionando diversão, descontração e apoio, o meu sincero agradecimento. Um agradecimento especial à minha amiga, Mariana Michels Fontoura, que forneceu apoio, encorajamento e orientação durante todo o processo de pesquisa e escrita. Suas amizades, conselhos e suporte foram fundamentais para a conclusão desta dissertação.

Meu reconhecimento também vai para o meu orientador, André Chaves Mendes, cuja orientação, paciência e expertise foram essenciais no desenvolvimento deste estudo. Sua capacidade de me incentivar e direcionar tornou possível chegar até aqui.

Por fim, mas não menos importante, agradeço a todos os participantes deste estudo por sua contribuição valiosa e imprescindível para a realização deste trabalho.

Este marco não é apenas um testemunho do meu esforço pessoal, mas um reflexo do amor, apoio e inspiração que recebi de todos vocês.

Resumo

Este trabalho explora a aplicação de dispositivos vestíveis e análise de *Big Data* na avaliação da qualidade de vida, com foco no bem-estar emocional. Utilizando dados fisiológicos coletados por dispositivos vestíveis, o sistema integrado desenvolvido emprega técnicas de análise de dados para compreender parâmetros de saúde como sono, atividade física, frequência cardíaca, estresse, ansiedade e tristeza. A implementação do sistema inclui a criação de uma arquitetura modular, o emprego do *Python* e *Django Framework* para o desenvolvimento *back-end* e *front-end*, e a configuração do banco de dados *InfluxDB* para gerenciar os dados de saúde. Além disso, o estudo incorpora um sistema de recomendações personalizadas, baseadas nas pontuações de saúde dos usuários, e uma interface intuitiva, que facilita a interação e o *feedback* do usuário.

Palavras-chave: Dispositivos Vestíveis, Análise de Dados, Bem-Estar, Métricas de Saúde.

Abstract

This work focuses on the application of wearable devices and Big Data analysis to assist with quality of life, focusing on emotional well-being. Using data collected by wearable devices, the developed integrated system employs data analysis techniques to understand health parameters such as sleep, physical activity, heart rate, stress, anxiety, and sadness. The system implementation includes the creation of a modular architecture, the use of Python and Django Framework for back-end and front-end development, and the configuration of the InfluxDB database to manage the health data's. Furthermore, the study incorporates a personalized recommendation system, based on the health scores of users, and an intuitive interface that facilitates user interaction and feedback.

Keywords: Wearable Devices, Data Analysis, Well-Being, Health Metrics.

Conteúdo

1	Introdução	1
1.1	Enquadramento	2
1.2	Objetivos	3
1.2.1	Objetivos Específicos	3
1.3	Estrutura do Documento	4
2	Estado da Arte	7
2.1	Contexto Atual	7
2.2	Desafio da Saúde Digital na Era Moderna	8
2.3	Dispositivos Vestíveis no Monitoramento da Saúde	9
2.4	Desafios Globais em Saúde Mental	10
2.5	Desafios e Oportunidades da Análise de Dados Emocionais	11
2.6	Tendências Atuais em Dispositivos Vestíveis	12
2.7	Papel das Tecnologias de Programação e Bancos de Dados	13
2.8	Importância da Usabilidade e Experiência do Usuário	14
2.9	Segurança e Privacidade de Dados em <i>e-Health</i>	16
2.10	Desenvolvimento de Algoritmos para Análise Comportamental	17
2.11	Avanços em Sensores e Tecnologia Vestível	17
2.12	Desafios de Adoção e Aceitação pelo Usuário	19
2.12.1	Vetores de Adoção	19
2.13	Futuro da Personalização em <i>e-Health</i>	20

3	Solução Proposta	23
3.1	Tecnologias e Ferramentas Utilizadas	24
3.2	Arquitetura do Sistema	27
3.2.1	Recolha de Dados	29
3.2.2	Avaliação dos Dados	33
3.2.3	Decisão	34
3.2.4	Ação no Ambiente	35
3.3	Quantificação de Estados Emocionais	36
3.4	Sistema de Recomendações	36
3.5	<i>Feedback</i> e Iteração	44
4	Desenvolvimento e Implementação	47
4.1	Gestão de Dados	47
4.2	Modelo de Recolha	48
4.2.1	Integração com Dispositivos Vestíveis e Armazenamento de Dados .	48
4.3	Modelo de Avaliação	50
4.3.1	Avaliação dos dados de Sono	50
4.3.2	Avaliação dos dados de Atividade	53
4.3.3	Avaliação dos dados da Frequência Cardíaca	55
4.3.4	Avaliação dos dados de <i>Feedback</i> de Tristeza	56
4.3.5	Pontuação de Estresse	60
4.3.6	Pontuação de Ansiedade	61
4.3.7	Pontuação de Tristeza	62
4.3.8	Armazenamento das pontuações	64
4.4	Modelo de Decisão	65
4.4.1	Modelo de Dados para Recomendações	65
4.5	Modelo de Ação no Ambiente	67
4.5.1	Estrutura Base das Páginas	67
4.5.2	Página Inicial	68

4.5.3	Página de Registro	69
4.5.4	Página de Login	70
4.5.5	Página do Usuário	72
4.5.6	Processo de Escolha de Recomendações	74
5	Resultados e Discussão	77
5.1	Análise dos Resultados	78
5.1.1	Verificação de Dados no <i>InfluxDB</i>	78
5.1.2	Verificação do Sistema de Pontuações	81
5.1.3	Impacto das Recomendações para Ansiedade e Tristeza	85
5.2	Discussão das Implicações	88
5.3	Objetivos Excedidos e Não Cumpridos	89
5.3.1	Objetivos Excedidos	90
5.3.2	Objetivos Não Cumpridos	91
5.4	Considerações Finais dos Resultados	92
6	Conclusões	93
6.1	Limitações e Desafios	94
6.2	Sugestões para Trabalhos Futuros	95
6.3	Considerações Finais	97
A	Códigos desenvolvidos no Capítulo 4	A1
B	Código da Página Inicial	B1

Lista de Tabelas

3.1	Tecnologias e ferramentas utilizadas no sistema <i>e-Health</i>	24
3.2	Recomendações baseadas no nível de estresse.	38
3.3	Recomendações baseadas no nível de ansiedade.	39
3.4	Recomendações baseadas no nível de tristeza.	40
3.5	Recomendações baseadas no nível de frequência cardíaca.	41
3.6	Recomendações baseadas no nível de atividade.	42
3.7	Recomendações baseadas no nível de qualidade do sono.	43

Lista de Figuras

3.1	Dispositivo Garmin Vivoactive 3 utilizado.	24
3.2	Aplicativo Garmin Connect.	26
3.3	Diagrama ilustrativo do mecanismo central da arquitetura do sistema de <i>e-Health</i>	28
3.4	Processo de recolha de dados no sistema <i>e-Health</i>	29
3.5	Funcionamento de uma API [108].	31
3.6	Ocorrência de erro por muitas chamadas em curto período.	32
3.7	Processo de avaliação dos dados no sistema <i>e-Health</i>	33
3.8	Processo decisório no sistema <i>e-Health</i>	34
3.9	Ações no ambiente baseadas nas decisões do sistema <i>e-Health</i>	35
3.10	Interface com as Recomendações no Administrador <i>Django</i>	44
3.11	Ilustração do ciclo de <i>feedback</i> e iteração no sistema <i>e-Health</i>	45
4.1	Interface de seleção de emoji para <i>feedback</i> do usuário.	58
4.2	Recomendações obtidas do painel administrativo do <i>Django</i>	66
4.3	Página inicial do sistema <i>e-Health</i>	69
4.4	Área de registro do usuário.	70
4.5	Área de <i>login</i> do usuário.	70
4.6	Seção de recomendações personalizadas na página do usuário.	73
5.1	Dados de frequência cardíaca.	78
5.2	Dados de contagem de passos.	79
5.3	Dados de qualidade do sono da última noite.	80

5.4	Dados de <i>feedback</i> de tristeza.	80
5.5	Pontuação da frequência cardíaca registrada no <i>InfluxDB</i>	81
5.6	Pontuação do <i>feedback</i> de Tristeza registrada no <i>InfluxDB</i>	82
5.7	Pontuação de atividade (passos) registrada no <i>InfluxDB</i>	82
5.8	Pontuação de qualidade do sono registrada no <i>InfluxDB</i>	83
5.9	Pontuação de nível de estresse registrada no <i>InfluxDB</i>	83
5.10	Pontuação de nível de ansiedade registrada no <i>InfluxDB</i>	84
5.11	Pontuação de nível de tristeza registrada no <i>InfluxDB</i>	84
5.12	Relação entre as pontuações para a Tristeza.	86
5.13	Relação entre as pontuações para a Ansiedade.	87

Capítulo 1

Introdução

Nos últimos anos, a análise de dados de saúde recolhidos através de dispositivos vestíveis tem ganhado destaque, especialmente na avaliação do bem-estar emocional e psicológico. O avanço significativo na miniaturização de dispositivos eletrônicos e a revolução na tecnologia de sensores flexíveis têm tornado os dispositivos vestíveis mais acessíveis e viáveis para o monitoramento contínuo da saúde, oferecendo um método conveniente e não invasivo para diagnósticos de doenças e avaliações de saúde [1], [2]. Entre os parâmetros de saúde mais relevantes estão a frequência cardíaca, a atividade física e a qualidade do sono, cada um com um papel significativo na modulação do humor, incluindo estados de tristeza, estresse e ansiedade [3]–[5].

Estudos recentes têm apontado para um aumento nos sentimentos negativos como ansiedade e tristeza na população [6]–[8]. Essa tendência crescente reflete a complexidade das interações entre fatores sociais, emocionais e psicológicos na configuração do bem-estar mental.

A relação entre a frequência cardíaca e o estado emocional, por exemplo, revela uma dinâmica complexa, onde alterações na frequência cardíaca podem refletir estados emocionais variados, desde a ansiedade até a calma, dependendo do contexto e da percepção individual. Um estudo publicado no *Anxiety Stress Coping* analisou esta relação em homens saudáveis, encontrando uma correlação entre o humor e a frequência cardíaca em um número restrito de sujeitos, principalmente naqueles com níveis mais altos de ansiedade

e estresse [9]–[11]. Além disso, a atividade física surge como um fator de modulação significativo para a saúde mental, com diferentes contextos de atividade física apresentando impactos variados no bem-estar [12]. A qualidade do sono também desempenha um papel crucial no humor, com a privação de sono podendo levar a irritabilidade, estresse e, em casos crônicos, a transtornos de humor como ansiedade e depressão [13], [14].

Frequência cardíaca, qualidade de sono e métricas de atividade física são apenas alguns dos dados de saúde que podem ser recolhidos e monitorados hoje pelas tecnologias vestíveis. Esta pesquisa se propõe a explorar como essas métricas de saúde podem ser utilizadas para avaliar e possivelmente melhorar o humor dos usuários. A crescente acessibilidade e viabilidade desses dispositivos, impulsionada pelo desenvolvimento de tecnologias de sensores flexíveis e sistemas eletrônicos de baixo consumo de energia, abrem novas perspectivas para a monitorização da saúde em tempo real e a gestão proativa do bem-estar [15], [16]. Considerando a complexidade das relações entre a saúde física, os estados emocionais e o bem-estar psicológico, o estudo visa compreender como a tecnologia vestível pode contribuir para a promoção da saúde mental em um cenário de crescente prevalência de sentimentos negativos na população.

1.1 Enquadramento

Este trabalho se insere no crescente campo da *e-Health*, com enfoque particular na utilização de dispositivos vestíveis para a coleta de informações relevantes à saúde e ao bem-estar. Situando-se na intersecção entre a tecnologia e a saúde, propõe a exploração de dados para extrair percepções significativas de variáveis fisiológicas.

O propósito deste estudo é desenvolver um sistema de análise integrada capaz de processar variáveis fisiológicas como número de passos, qualidade do sono e frequência cardíaca, coletadas por dispositivos vestíveis. Utilizando métodos de análise de dados, o sistema visa interpretar a condição de bem-estar dos usuários, identificando padrões que possam estar associados a estados emocionais específicos como ansiedade, estresse e tristeza.

Através deste sistema, pretende-se construir modelos que quantifiquem esses estados emocionais. Com base nesses modelos, a investigação buscará desenvolver recomendações personalizadas, integrando *feedback* dos usuários aos dados fisiológicos coletados. Estas recomendações podem incluir desde sugestões de atividades físicas pensadas para o usuário até técnicas de relaxamento, como a música, com o objetivo de oferecer uma abordagem personalizada a fim de minimizar os estados emocionais negativos.

Este estudo visa um avanço em direção à aplicação prática de dispositivos vestíveis e análise de dados para um monitoramento mais abrangente e personalizado da saúde e do bem-estar. A combinação desses elementos tem o potencial de facilitar intervenções personalizadas, contribuindo assim para uma melhor gestão da saúde e do bem-estar emocional dos usuários.

1.2 Objetivos

O presente trabalho teve como objetivo desenvolver um sistema de *e-Health* para monitoramento e análise de indicadores de bem-estar emocional e de um sistema de recomendações de melhoria dos mesmos. Os dados utilizados pelo sistema são recolhidos por um dispositivo vestível, que resultam nas recomendações após a análise destes dados.

1.2.1 Objetivos Específicos

- Revisão de literatura e trabalhos relacionados a fim de formar a base teórica para construção do sistema.
- Implementar um sistema utilizando um vestível para monitorar indicadores de saúde, incluindo frequência cardíaca, atividade física, qualidade do sono e estados emocionais como estresse, ansiedade e tristeza.
- Utilizar um banco de dados para armazenar, processar e garantir a integridade dos dados recolhidos.

- Desenvolver algoritmos para calcular pontuações de saúde e bem-estar emocional, com base nos dados recolhidos e no *feedback* do usuário.
- Avaliar a eficácia do sistema *e-Health* por meio de testes de funcionalidade e análise de dados.
- Investigar como as recomendações do sistema influenciam a melhoria dos indicadores de saúde e bem-estar dos usuários, observando as mudanças nas pontuações relacionadas.
- Examinar a conexão entre comportamentos de saúde (como atividade física e qualidade do sono) e pontuações de tristeza, ansiedade e estresse para entender a interação entre esses fatores.
- Sugerir melhorias e possíveis expansões para o sistema *e-Health*, com base nas limitações identificadas e nas oportunidades de aprimoramento descobertas durante os testes.

1.3 Estrutura do Documento

Este relatório abrange uma investigação voltado para a aplicação de tecnologias digitais e análise de dados no contexto da *e-Health*. O documento é organizado da seguinte forma:

- **Capítulo 2 - Estado da Arte:** (2) Este capítulo apresenta uma visão geral no âmbito da *e-Health*, seus avanços e desafios atuais, incluindo uma revisão da literatura. A seção é estruturada em seções para uma melhor organização e compreensão dos tópicos.
- **Capítulo 3 - Solução Proposta:** (3) Detalha a proposta de solução, elucidando a aplicação de técnicas de análise e modelação para definir as tarefas do sistema e interações. Este capítulo aborda os caminhos escolhidos para solucionar a proposta do tema.

- **Capítulo 4 - Desenvolvimento e Implementação:** (4) Este capítulo se dedica ao processo de desenvolvimento, exemplificando os métodos utilizados e delineando a solução proposta para alcançar os objetivos iniciais estabelecidos. Além disso, exemplifica a integração entre o código desenvolvido para o estudo e suas funcionalidades.
- **Capítulo 5 - Resultados e Discussão:** (5) Detalha as ações realizadas para validar o estudo, discutindo os resultados e refletindo sobre os objetivos que foram alcançados e os que não foram, através das implementações feitas.
- **Capítulo 6 - Conclusões:** (6) Sintetiza o trabalho, oferecendo uma visão unificada e destacando o conhecimento adquirido. Também aborda as limitações e dificuldades do trabalho, além de sugerir direções para trabalhos futuros.

Esta estrutura foi desenhada para garantir uma compreensão completa e detalhada da investigação, abrangendo desde a formulação do problema até a avaliação final do sistema desenvolvido.

Capítulo 2

Estado da Arte

2.1 Contexto Atual

A evolução tecnológica tem impulsionado a adoção de dispositivos vestíveis para o monitoramento contínuo da saúde, refletindo uma tendência crescente em direção a soluções de e-Health personalizadas e adaptativas. Esses dispositivos recolhem dados essenciais que permitem o acompanhamento detalhado e em tempo real das condições de saúde dos indivíduos. A integração dessas tecnologias no dia a dia tem revolucionado a maneira como se monitora e entende a saúde, facilitando a detecção precoce de potenciais problemas e permitindo intervenções mais rápidas e informadas [17]. A popularização dos smartphones e o aumento da conectividade têm fomentado o desenvolvimento de aplicativos de saúde que se sincronizam com esses dispositivos, oferecendo uma plataforma integrada para a gestão da saúde pessoal [17].

Além de melhorar a eficácia e a disponibilidade dos sistemas de *e-Health*, a integração de dispositivos vestíveis apresenta oportunidades para criar ecossistemas adaptados às necessidades em mudança dos usuários ao longo da vida, tanto em saúde quanto em doença. Essa integração está impulsionando mudanças nos modelos de entrega de cuidados de saúde e na relação entre pacientes e prestadores de cuidados de saúde [18]. Entretanto,

desafios significativos surgem em relação à implementação dessas novas tecnologias, incluindo a privacidade e segurança dos dados, regulamentação, adaptação dos sistemas ao indivíduo e o crescente volume de informações na prática clínica e nos fluxos de trabalho [18].

A adoção de tecnologias vestíveis em sistemas de *e-Health* melhora significativamente a eficácia e a disponibilidade desses sistemas [19]. Os usuários podem carregar suas informações pessoais de saúde na nuvem, de onde os prestadores de serviços de saúde podem obter informações apropriadas para avaliar o estado de saúde atual [19].

A integração de dispositivos vestíveis em sistemas de *e-Health* representa uma evolução importante no monitoramento e gestão da saúde. É relevante ressaltar que existem desafios, especialmente no que diz respeito à privacidade dos dados e adaptação dos sistemas, mas as oportunidades que se apresentam para melhorar a qualidade de vida dos usuários são inegáveis. A combinação de tecnologias avançadas e uma abordagem centrada no paciente é essencial para o sucesso dessa integração, promovendo uma saúde mais personalizada e proativa.

2.2 Desafio da Saúde Digital na Era Moderna

A era digital inaugurou uma nova fase na maneira como os indivíduos gerenciam sua saúde e bem-estar. O advento de tecnologias emergentes, como dispositivos vestíveis e aplicativos de saúde móveis, tem potencial para transformar radicalmente o monitoramento da saúde pessoal [20], [21]. Esses avanços oferecem a promessa de maior autonomia para os usuários na gestão da própria saúde, fornecendo dados em tempo real sobre indicadores fisiológicos e hábitos de vida.

Um dos desafios mais significativos reside na garantia da precisão e confiabilidade dos dados coletados por esses dispositivos. A precisão dos dados é fundamental, pois informações imprecisas podem levar a interpretações errôneas e, conseqüentemente, a decisões de saúde inadequadas [22], [23]. Além da precisão dos dados, outro desafio primordial é a segurança e a privacidade das informações de saúde [24], [25]. Com o

aumento na recolha e no armazenamento de dados de saúde pessoais, crescem também as preocupações com a proteção desses dados contra acessos não autorizados e violações.

Esses desafios apontam para a necessidade de uma abordagem holística na adoção de tecnologias de saúde digital, onde a precisão dos dados, a segurança da informação e a experiência do usuário sejam consideradas de maneira integrada. A proteção da privacidade e a segurança dos dados são preocupações primárias, exigindo uma consideração cuidadosa das implicações éticas do uso dessas tecnologias [26]. A transição para uma saúde mais tecnológica deve ser realizada com uma visão abrangente, garantindo que as inovações tragam benefícios reais e tangíveis para os usuários, sem comprometer sua segurança e privacidade.

2.3 Dispositivos Vestíveis no Monitoramento da Saúde

A ascensão dos dispositivos vestíveis no cenário da saúde é uma mudança paradigmática notável. Esses dispositivos evoluíram de simples contadores de passos para sistemas complexos de monitoramento de saúde, desempenhando um papel vital no acompanhamento de indicadores biométricos como frequência cardíaca, qualidade do sono e níveis de atividade física [2].

Estes dispositivos não são apenas ferramentas de recolha de dados, eles promovem um estilo de vida mais saudável e consciente. O monitoramento contínuo proporciona aos usuários um entendimento mais profundo de seu bem-estar físico e mental, habilitando uma gestão proativa da saúde [27].

A popularidade crescente dos dispositivos vestíveis reflete a tendência em direção à saúde digital e ao auto-cuidado. Eles são úteis não apenas para monitoramento individual, mas também fornecem percepções valiosas para pesquisas em saúde, contribuindo para a melhoria da prevenção e tratamento de doenças [28].

A integração destes dispositivos na vida cotidiana tem um impacto positivo significativo na saúde dos usuários. O *feedback* em tempo real e a visibilidade constante da saúde

peçoal incentivam comportamentos saudáveis e conscientes. A eficácia destes dispositivos, no entanto, depende da sua precisão, usabilidade e integração com outras plataformas de saúde. [29].

2.4 Desafios Globais em Saúde Mental

Nos últimos anos, testemunhou-se um agravamento nos índices de ansiedade, tristeza e estresse entre a população global. Este fenômeno tem sido vinculado a uma gama de fatores sociais, econômicos e ambientais, contribuindo para um crescente desafio da saúde mental mundialmente [30], [31]. A evidência empírica revela um incremento significativo nas prevalências de tais sentimentos, não somente em grupos específicos, como estudantes universitários, mas também na população em larga escala [32], [33]. A ascensão desses estados emocionais adversos está correlacionada ao impacto de eventos globais de grande escala e às exigências da vida contemporânea, exacerbando condições de saúde mental já existentes.

Além disso, os efeitos a longo prazo do estresse crônico, bem como dos prolongados estados de ansiedade e tristeza, transcendem a esfera da saúde mental, repercutindo também fisicamente. Estas condições elevam o risco de doenças crônicas, além de propiciar alterações cerebrais que comprometem a regulação emocional e aumentam a suscetibilidade a distúrbios psiquiátricos [30], [31]

Diante destes desafios, observa-se um interesse crescente por intervenções não convencionais, como as terapias baseadas em *mindfulness* e a prática regular de exercícios físicos. Tais métodos têm se mostrado eficazes na atenuação dos sintomas de ansiedade, tristeza e estresse, representando alternativas valiosas ao lado dos tratamentos tradicionais para saúde mental [34], [35]. O avanço destas abordagens sinaliza um caminho promissor para a redução do impacto negativo destes sentimentos sobre o bem-estar das pessoas.

O crescente volume de sintomas de baixa qualidade de bem estar emocional como ansiedade, tristeza e estresse sinalizam um desafio significativo para a saúde em nível mundial. Deste modo, destaca-se a necessidade em desenvolver e implementar estratégias

preventivas para manutenção do bem estar e saúde mental. A evolução científica nesta área sublinha a urgência de abordagens inovadoras e acessíveis para promover a saúde mental e o bem-estar geral [36], [37].

2.5 Desafios e Oportunidades da Análise de Dados Emocionais

À medida que a análise de dados se torna mais integrada à saúde digital, ela traz consigo uma nova era de oportunidades para compreender e melhorar o bem-estar emocional. Dispositivos vestíveis, que monitoram uma variedade de parâmetros fisiológicos, estão cada vez mais integrados em plataformas analíticas avançadas para explorar correlações com estados emocionais [38]. A utilização de modelos computacionais avançados permite o desenvolvimento de algoritmos para identificar sinais de ansiedade e outras emoções, abrindo portas para intervenções mais eficazes e personalizadas [39].

A inovação em tecnologias, como as que criam modelos virtuais detalhados e dinâmicos de indivíduos ou sistemas, oferece caminhos promissores para o monitoramento e apoio ao bem-estar mental. Esses modelos digitais, construídos a partir de dados do mundo real, permitem simulações e análises em tempo real do estado emocional e comportamental de uma pessoa, promovendo intervenções personalizadas e proativas [40]–[43]. Estas ferramentas estão sendo exploradas em diversos contextos, desde o monitoramento da saúde mental dos estudantes até a prevenção de doenças crônicas [44]. A computação vestível, em particular, tem mostrado um grande potencial para detectar e responder a alterações no bem-estar emocional, destacando a importância da análise de parâmetros psicológicos [45].

Apesar dos avanços, a integração de análises de dados na prática clínica e nos serviços de saúde ainda enfrenta desafios significativos. A personalização e a digitalização dos cuidados de saúde, portanto, requerem uma abordagem equilibrada que reconheça tanto o potencial quanto as limitações dos dados em grande escala [46].

2.6 Tendências Atuais em Dispositivos Vestíveis

A esfera de *e-Health* tem presenciado uma evolução significativa, marcada principalmente pela ascensão e adoção de dispositivos vestíveis, que se tornaram fundamentais para as inovações na saúde digital. Estes dispositivos recolhem dados fisiológicos vitais, revolucionando a forma como o monitoramento e a gestão da saúde pessoal são conduzidos. Eles permitem o acompanhamento contínuo de uma vasta gama de indicadores de saúde, incluindo frequência cardíaca, qualidade do sono e níveis de atividade física.

A trajetória desses dispositivos na última década tem sido notável. Evoluindo de simples pedômetros para complexos sistemas de monitoramento de saúde, oferecem funcionalidades que transcendem a simples contagem de atividades, abrangendo o rastreamento de sinais vitais e biométricos [17]. Esta tendência é coerente com os movimentos globais na saúde digital, onde a digitalização e o aprimoramento qualitativo dos serviços médicos têm promovido a proliferação de dispositivos eletrônicos vestíveis pessoais e tecnologias da informação e comunicação (TIC) [47].

Além disso, a sinergia entre dispositivos vestíveis e a Internet das Coisas (IoT) tem desbloqueado novas possibilidades para a saúde integrada. Sua crescente incorporação em sistemas de saúde está facilitando a recolha e análise em larga escala de dados para aprimorar a prevenção e o tratamento de condições de saúde [48]. A tecnologia de vestíveis está avançando para abranger sensores e dispositivos que são flexíveis e adaptáveis, pavimentando o caminho para uma era de interação mais natural e confortável com a tecnologia [49].

O desenvolvimento em dispositivos vestíveis flexíveis é notável, preparando o cenário para a nova geração de vestíveis que se integram de maneira mais harmoniosa ao corpo, fornecendo funcionalidades avançadas sem comprometer o conforto [50]. Pesquisas em vestíveis também estão investigando maneiras de aumentar a eficiência energética, fundamental para a funcionalidade prolongada dos dispositivos [51].

Em resumo, o panorama atual dos dispositivos vestíveis em *e-Health* sinaliza uma tendência em direção a dispositivos mais integrados, personalizados e eficientes em termos

energéticos, que prometem transformar profundamente o acompanhamento da saúde e o bem-estar pessoal [52].

2.7 Papel das Tecnologias de Programação e Bancos de Dados

O papel das tecnologias de programação e bases de dados é fundamental no campo de *e-Health*. A capacidade de gerenciar e analisar grandes volumes de dados é essencial para extrair percepções pertinentes que apoiam a compreensão e o tratamento de questões de saúde mental e emocional. Linguagens de programação especializadas, como *Python*, e sistemas de gerenciamento de bancos de dados são ferramentas cruciais para o processamento eficiente desses dados, permitindo uma análise robusta e a aplicação de algoritmos. [53].

O avanço na modelagem de bancos de dados em saúde é igualmente vital. A modelagem adequada desses sistemas é indispensável para uma organização eficaz das informações médicas, facilitando a estruturação, o armazenamento seguro e a recuperação rápida de dados para análise e processamento [54].

Em resumo, a infraestrutura tecnológica de *e-Health* é sustentada pela combinação de linguagens de programação dedicadas e bases de dados especializadas. Estas ferramentas são essenciais não só para a gestão eficiente de dados de saúde, mas também para ampliar a capacidade de análise e interpretação, impulsionando progressos significativos na área da saúde mental e emocional [55].

Um dos desafios mais prementes em *e-Health* é a interoperabilidade e a atualização oportuna dos dados de saúde. A diversidade de formatos de dados e padrões adotados por diferentes sistemas de saúde amplifica a complexidade do gerenciamento de dados em tempo real, onde a precisão e a atualização contínua são cruciais para a eficácia dos sistemas de saúde digitais.

A interoperabilidade é a capacidade de diferentes sistemas e organizações compartilharem e utilizarem informações de maneira eficiente. A natureza fragmentada dos sistemas de saúde, cada um operando com seus próprios padrões e formatos de dados, cria barreiras significativas para a integração e compartilhamento eficaz de informações. Esta situação é complicada pela constante inovação tecnológica e pela necessidade de adaptar-se à integração de novos tipos de dados, como os originados de tecnologias vestíveis [56].

O desenvolvimento de ontologias de saúde e a adoção de linguagens de marcação semântica podem melhorar a interoperabilidade no nível semântico, assegurando que os dados sejam não apenas compartilhados, mas também interpretados consistentemente entre sistemas distintos [57].

Quanto à atualização de dados, a exigência de um ambiente de saúde digital que suporte decisões clínicas baseadas em dados em tempo real implica a necessidade de métodos eficazes de processamento e sincronização de dados. É vital que os sistemas de saúde sejam capazes de atualizar e sincronizar informações de maneira eficiente para que dados recentes estejam sempre disponíveis para os usuários [58].

Em resumo, a saúde digital traz oportunidades sem precedentes para melhorar os cuidados e o bem-estar dos usuários, mas também apresenta desafios substanciais em termos de interoperabilidade e atualização de dados. Enfrentar esses desafios é crucial para assegurar que os sistemas de saúde digitais sejam eficientes, seguros e centrados no usuário[59].

2.8 Importância da Usabilidade e Experiência do Usuário

A concepção de interfaces *web* com alta usabilidade é crucial para assegurar uma experiência positiva do usuário nos sistemas de *e-Health*. A usabilidade, facilidade com que os usuários podem utilizar uma interface para alcançar seus objetivos de forma eficaz,

eficiente e satisfatória, é um componente determinante no desenvolvimento de plataformas de saúde digital eficientes, exigindo interfaces que sejam ao mesmo tempo acessíveis e intuitivas para facilitar a adoção tecnológica [60], [61]. A experiência do usuário (UX), neste contexto, transcende a mera facilidade de uso, visando a criação de percursos de interação que sejam coerentes, intuitivos e gratificantes [60], [61].

A relevância de uma metodologia de design centrada no usuário para sistemas de saúde digital, enfatiza que a usabilidade e a experiência do usuário são essenciais para garantir que as tecnologias sejam funcionais, acessíveis e prazerosas de utilizar. Isto é particularmente crítico no domínio da saúde, onde uma experiência negativa pode influenciar diretamente a eficácia do tratamento e a administração da saúde [62].

No que tange à usabilidade dos sistemas de registro eletrônico de saúde (EHR), a simplicidade na navegação, a clareza da interface e a facilidade de inserção de dados são fundamentais para a produtividade e satisfação dos usuários. Estes elementos são vitais para assegurar que os profissionais de saúde possam dedicar sua atenção ao cuidado dos pacientes, minimizando o tempo despendido em interações com interfaces complexas [63].

Outro fator é das notificações push, a frequência dessas notificações, mais do que a personalização baseada no contexto, como a localização, impacta positivamente o engajamento dos usuários. Usuários que recebem notificações com maior frequência interagem mais com o aplicativo do que aqueles que receberam notificações menos frequentes. Isso sugere que um número maior de notificações pode levar a uma maior atenção ao conteúdo do aplicativo, sem necessariamente prejudicar o interesse do usuário [64].

Em síntese, a usabilidade e a experiência do usuário são aspectos fundamentais no desenho de sistemas de *e-Health*. Enfatizando esses componentes, é viável não apenas potencializar a adesão e contentamento do usuário, mas também incrementar a qualidade dos cuidados de saúde e a eficácia operacional dos sistemas [65].

2.9 Segurança e Privacidade de Dados em *e-Health*

A segurança e a privacidade dos dados representam pilares fundamentais para a confiabilidade e a sustentabilidade dos sistemas de *e-Health*. A natureza delicada das informações de saúde exige estratégias rigorosas e metodologias robustas para garantir a confidencialidade e a integridade dos dados dos pacientes. Em um setor caracterizado por rápidas inovações tecnológicas e crescentes volumes de dados digitais, a segurança da informação torna-se um campo dinâmico e complexo, com implicações diretas para desenvolvedores, profissionais de saúde e usuários finais.

O advento de tecnologias emergentes, como sensores avançados, redes de comunicação e plataformas de computação em nuvem, intensificou as preocupações relacionadas à segurança dos dados no contexto da saúde digital. Abordar eficientemente a segurança e a privacidade em *e-Health* requer um entendimento abrangente dos riscos, bem como o desenvolvimento de soluções que sejam tanto proativas quanto reativas [66], [67].

A proteção da privacidade dos pacientes é uma preocupação preeminente, especialmente considerando a facilidade com que dados podem ser armazenados e acessados na era digital. O risco potencial de uso indevido dessas informações sensíveis necessita de um equilíbrio entre acessibilidade e proteção, demandando que conceitos de privacidade e segurança sejam implementados de forma rigorosa e considerada [68].

Ademais, estratégias como a autenticação biométrica do lado do servidor em sistemas dinâmicos de *e-Health* realçam a importância de proteger não apenas os dados, mas também a identidade dos usuários. A manutenção da anonimidade e a indetectabilidade das comunicações durante processos de autenticação e negociação de chaves tornam-se então componentes críticos das soluções de segurança [69].

Em resumo, embora as tecnologias digitais na saúde apresentem oportunidades sem precedentes para o aprimoramento do atendimento ao paciente, elas trazem consigo desafios significativos relacionados à segurança e privacidade dos dados. Enfrentar esses desafios é imperativo para assegurar que os sistemas de saúde digital sejam confiáveis, eficientes e orientados ao paciente [70].

2.10 Desenvolvimento de Algoritmos para Análise Comportamental

A utilização de algoritmos avançados para a análise de padrões comportamentais e emocionais é uma das inovações mais promissoras na *e-Health*. Com a prevalência de dispositivos vestíveis que capturam dados fisiológicos e comportamentais, emerge uma oportunidade única de aprofundar o entendimento e influenciar o bem-estar mental e emocional.

Essa vertente de *e-Health* emprega métodos de aprendizado de máquina e inteligência artificial para processar conjuntos de dados complexos, possibilitando a identificação de padrões e tendências que informam sobre o comportamento e o estado emocional dos usuários. Variações na frequência cardíaca e modificações em padrões de atividade e sono podem sinalizar mudanças no nível de estresse ou humor, oferecendo dados valiosos para a prevenção e tratamento de transtornos psicológicos.

A combinação de dados comportamentais e biométricos potencializa o desenvolvimento de modelos preditivos para compreender as necessidades dos pacientes com maior precisão e fornecer cuidados de saúde personalizados. Isso é particularmente relevante para a detecção precoce de condições como depressão e ansiedade e para a recomendação de intervenções personalizadas em saúde mental [71].

Em conclusão, o desenvolvimento de algoritmos para análise comportamental está definindo novas diretrizes para a compreensão do bem-estar mental e emocional, potencializando a capacidade de monitorar e intervir de maneira eficaz, o que é fundamental para o avanço do cuidado com a saúde mental [72].

2.11 Avanços em Sensores e Tecnologia Vestível

O avanço em tecnologias vestíveis está impulsionando transformações significativas na *e-Health*, com aprimoramentos contínuos em sensores e dispositivos que estendem as fronteiras do monitoramento e análise de saúde. Estes progressos conduzem a uma abordagem

de cuidado de saúde mais personalizado e preventivo, abrindo novos horizontes para o monitoramento contínuo e a administração efetiva das condições de saúde.

Inovações em sensores vestíveis têm alcançado marcos notáveis, proporcionando medições cada vez mais precisas de indicadores vitais, tais como frequência cardíaca, níveis de oxigênio no sangue, padrões de sono e atividade física. A evolução dos sensores tem permitido captura de dados biométricos mais complexos, enquanto a incorporação de tais sensores em roupas e acessórios está fomentando novas metodologias para um monitoramento de saúde discreto e ininterrupto [73], [74].

Entre essas inovações, os sensores de glicose contínuos (CGMs) representam um avanço revolucionário para o gerenciamento do diabetes, permitindo que os usuários monitorem seus níveis de glicose em tempo real sem a necessidade de testes invasivos de picada no dedo. Esses dispositivos melhoram significativamente a qualidade de vida dos pacientes com diabetes, fornecendo dados contínuos que podem ajudar na tomada de decisões mais informadas sobre dieta, exercício e medicação [75], [76].

Além disso, a emergência de anéis inteligentes exemplifica a evolução da tecnologia vestível em direção a dispositivos mais discretos e esteticamente agradáveis. Esses anéis, equipados com sensores avançados, são capazes de monitorar uma variedade de parâmetros de saúde, como frequência cardíaca, temperatura corporal, padrões de sono e até mesmo níveis de atividade física. Sua discreta integração na vida diária dos usuários permite um monitoramento contínuo sem comprometer o conforto ou a conveniência, representando um passo significativo em direção a um ecossistema de saúde integrado e acessível [77], [78].

A integração de sensores avançados em dispositivos vestíveis está revolucionando a prática de monitoramento da saúde, facilitando a detecção precoce de condições adversas e melhorando a gestão de doenças crônicas. Isso não só eleva a qualidade de vida dos usuários, mas também fornece aos profissionais de saúde informações detalhadas e confiáveis, cruciais para diagnósticos precisos e planos de tratamento eficazes [79].

Apesar destes avanços, existem desafios significativos relacionados à precisão, privacidade e aceitação dos usuários que os dispositivos vestíveis enfrentam. A integração desses

dispositivos com os sistemas de saúde existentes e a padronização dos dados coletados são cruciais para o avanço contínuo desta tecnologia. Estratégias para superar esses obstáculos, com o objetivo de maximizar as capacidades dos dispositivos vestíveis em *e-Health*, constituem um campo ativo de pesquisa [80].

Conforme a tecnologia avança, antecipa-se que dispositivos vestíveis se tornarão cada vez mais integrados ao cotidiano do cuidado com a saúde, provendo dados contínuos e percepções valiosas que podem enriquecer tanto o autocuidado quanto a assistência médica profissional.

2.12 Desafios de Adoção e Aceitação pelo Usuário

A adesão a soluções de *e-Health* é um fenômeno multidimensional, afetado por fatores como usabilidade, confiança e valor percebido. Uma análise profunda dessas variáveis é imperativa para otimizar a aceitação e implementação eficaz de tecnologias de saúde digital.

2.12.1 Vetores de Adoção

- **Usabilidade:** Interfaces de usuário que promovem uma interação intuitiva e sem esforço são decisivas para a adoção de sistemas de *e-Health*. A complexidade e a falta de intuição podem desencorajar o uso e diminuir a aceitação [81].
- **Confiança:** A confiabilidade percebida nas tecnologias de *e-Health*, incluindo a precisão dos dados e a robustez das medidas de segurança de privacidade, é um pilar central para a aceitação do usuário. As preocupações com a privacidade dos dados influenciam diretamente a disposição de uso [82].
- **Percepção de Valor:** A adoção é fortemente influenciada pela percepção de benefícios concretos e melhorias no cuidado à saúde oferecidos pela tecnologia. O valor percebido é uma alavanca crítica para a aceitação de soluções de *e-Health* [83].

A incorporação bem-sucedida de tecnologias de *e-Health* no cotidiano do usuário depende de abordar efetivamente fatores como usabilidade, confiança e valor percebido. Ao implementar soluções com design centrado no usuário, prover recursos educacionais adequados e comunicar transparentemente sobre práticas de segurança de dados, é possível aprimorar a aceitação e eficácia das soluções de saúde digital. Esses esforços são essenciais para fomentar a confiança, promover a satisfação do usuário e assegurar uma adoção mais ampla das inovações em *e-Health*, contribuindo assim para uma experiência de saúde conectada, personalizada e centrada no paciente.

2.13 Futuro da Personalização em *e-Health*

O conceito de personalização em *e-Health* é uma abordagem revolucionária que visa a adaptar os cuidados de saúde às singularidades genéticas, comportamentais e preferenciais de cada indivíduo. Esta personalização é impulsionada pelo avanço de tecnologias disruptivas e pelo reconhecimento de que os cuidados de saúde uniformizados podem não ser eficazes para todos os pacientes devido à intrínseca variabilidade humana.

A saúde personalizada está reformulando a prevenção, o diagnóstico, o tratamento e o monitoramento, visando a maximizar a eficácia terapêutica e promover a adesão dos pacientes, culminando em melhorias nos desfechos clínicos e na satisfação do paciente. A concretização deste potencial passa pela integração de dados genômicos, exposômicos, comportamentais e clínicos, recolhidos através de dispositivos vestíveis e outras tecnologias digitais, e sua análise por meio de algoritmos avançados de *Big Data* e aprendizado de máquina [84].

A personalização, no entanto, enfrenta desafios substanciais, como a segurança de dados sensíveis, a necessidade de interoperabilidade entre sistemas heterogêneos e a importância da validação clínica de algoritmos preditivos. Questões éticas e regulatórias também são preponderantes, especialmente quando se considera o potencial de discriminação com base em perfis genéticos ou riscos de saúde. Além disso, a transição para um modelo de saúde mais centrado no paciente exige alterações significativas nas estruturas

e na cultura organizacional dos sistemas de saúde [85].

Avanços nas técnicas de criptografia e no desenvolvimento de políticas de privacidade robustas são vitais para proteger as informações dos pacientes, enquanto a implementação de padrões de interoperabilidade e o desenvolvimento de interfaces de programação de aplicações (APIs) são necessários para facilitar a integração e análise de dados de saúde. A personalização em *e-Health* também requer uma avaliação contínua das implicações tecnológicas, éticas e sociais para garantir que as inovações sejam implementadas de forma responsável e justa.

Em síntese, enquanto a personalização em *e-Health* promete um futuro onde o atendimento ao paciente é altamente adaptado e mais eficaz, a sua realização plena dependerá do avanço harmonioso da tecnologia, da regulamentação e da ética, assegurando que os benefícios da saúde digital sejam acessíveis a todos e reflitam os valores da sociedade [86].

Capítulo 3

Solução Proposta

Este capítulo delinea a solução desenvolvida para recolher dados fisiológicos do usuário, avaliar esses dados e permitir a tomada de ações com o objetivo de melhorar a saúde e o bem-estar emocional do usuário, detalhando a estrutura e as tecnologias empregadas. A solução proposta utiliza dados quantitativos provenientes de dispositivos vestíveis, especificamente do relógio Garmin Vivoactive 3, que monitora aspectos da saúde do usuário, como frequência cardíaca, atividade física e qualidade do sono. Esses dados são essenciais para quantificar os estados emocionais do usuário, como ansiedade, estresse e tristeza, convertendo-os em pontuações objetivas.

Para processar e analisar esses dados, a solução integra um sistema composto pelo banco de dados *InfluxDB* e pela linguagem de programação *Python*, facilitando uma análise multidimensional dos dados para melhor compreensão e melhoria do bem-estar emocional do usuário.

Este estudo utiliza uma metodologia apoiada em teorias que ligam variáveis fisiológicas, captadas por dispositivos vestíveis, ao bem-estar emocional. Pesquisas em *e-Health* destacam a importância dessas variáveis como indicadores de bem-estar psicológico, fundamentando a abordagem desta investigação [87], [88].

As seções seguintes irão apresentar as tecnologias, ferramentas e procedimentos adotados na solução proposta. A implementação específica e a descrição técnica detalhada desses elementos serão abordadas no capítulo subsequente.

3.1 Tecnologias e Ferramentas Utilizadas

Esta investigação utiliza uma combinação de dispositivo vestível, banco de dados, linguagens de programação e tecnologias web, vistos na Tabela 3.1, cada um contribuindo com suas capacidades únicas para formar uma solução integrada e eficaz.

Tecnologia/- Ferramenta	Categoria	Descrição
Garmin	Dispositivo Vestível	Monitoramento de saúde, incluindo frequência cardíaca e padrões de atividade.
InfluxDB	Banco de Dados	Banco de dados otimizado para séries temporais, eficiência e escalabilidade.
Python e Django	Linguagens e Frameworks Back-end	Versatilidade e poderosos frameworks de análise de dados, robustez e recursos de segurança.
HTML, Bootstrap e JavaScript	Linguagens e Frameworks Front-end	Experiência de usuário responsiva e intuitiva, design centrado no usuário.

Tabela 3.1: Tecnologias e ferramentas utilizadas no sistema *e-Health*.

O dispositivo utilizado para o estudo foi o Garmin Vivoactive 3, um dispositivo vestível tecnologicamente avançado, equipado com sensores especializados para monitoramento de parâmetros de saúde e atividade física [89]. Outras marcas do mercado, como Fitbit [90], Polar [91], Samsung [92] e Apple [93], oferecem dispositivos com capacidades de obtenção de dados semelhantes, mas o Vivoactive 3 foi selecionado por ser o dispositivo que estava disponível e atendia aos propósitos do estudo. A Figura 3.1 ilustra o relógio utilizado.



Figura 3.1: Dispositivo Garmin Vivoactive 3 utilizado.

Para o propósito desta pesquisa, foram empregados sensores específicos que fornecem

dados relacionados à frequência cardíaca, níveis de estresse, atividade física e padrões de sono. O sensor de frequência cardíaca óptico, operando com base na tecnologia de fotople-tismografia (PPG), permite a medição contínua da frequência cardíaca e identificação de variações fisiológicas associadas ao estresse e à atividade física [27], [94]. O acelerômetro triaxial, essencial para o rastreamento de movimento, fornece dados quantitativos sobre a atividade física do usuário, como contagem de passos e tipos de movimentos, refletindo o nível de atividade [16], [95]. O sistema de monitoramento do sono, que integra dados do acelerômetro e do sensor de frequência cardíaca, avalia a qualidade do sono ao medir duração, regularidade e identificação das fases do sono [2], [94]. Estes sensores foram selecionados devido à sua relevância direta na avaliação do bem-estar físico e emocional do usuário.

Neste contexto, a utilização da *Health API*, integrante do Garmin Connect Developer Program, emerge como um recurso valioso, permitindo o acesso a informações padronizadas e em tempo real derivadas de dispositivos vestíveis da Garmin. Este programa oferece aos desenvolvedores a possibilidade de criar aplicações que se integram aos dados gerados por esses dispositivos, fornecendo uma visão detalhada de várias métricas de saúde, tais como atividade física, saúde cardiovascular, qualidade do sono e níveis de estresse. O acesso à Health API é concedido mediante uma solicitação formal ao Garmin Connect Developer Program. Com a aprovação dessa solicitação, é possível obter uma gama extensa de dados, tanto em tempo real quanto históricos, o que representa um contributo significativo para a pesquisa. Assim, os dados adquiridos através da Health API são essenciais para estabelecer correlações pertinentes, destacando o papel das tecnologias vestíveis e da análise dos dados na avaliação da qualidade de vida e do bem-estar emocional.

O aplicativo Garmin Connect, que fornece os dados pela API, apresenta todas as informações obtidas do relógio, garantindo o acesso a informações padronizadas e em tempo real. Um exemplo da disponibilização dessas informações no aplicativo Garmin Connect pode ser observado na Figura 3.2. Estas métricas são amplamente reconhecidas na pesquisa de saúde por estabelecer correlações entre atividade física, saúde cardiovascular, qualidade do sono e níveis de estresse [96].

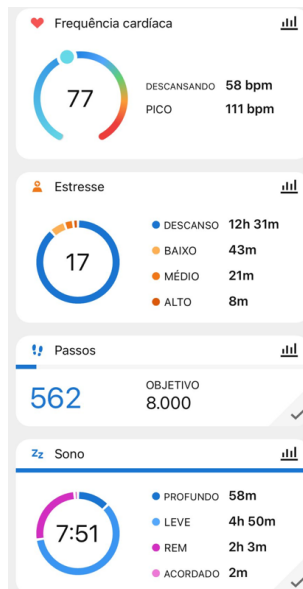


Figura 3.2: Aplicativo Garmin Connect.

Para o armazenamento e gerenciamento dos dados foi utilizado o *InfluxDB*, um banco de dados otimizado para o tratamento de séries temporais, também poderia ser utilizado o *MongoDB* ou *PostgreSQL*. A escolha do *InfluxDB* se deve à eficiência, escalabilidade e habilidade em lidar com grandes volumes de dados, características essenciais para sistemas de saúde que dependem da precisão e da disponibilidade imediata de informações [97].

A análise de dados e a lógica de *backend*, bem como elementos chave da interface de usuário, como áreas de login e registro, foram desenvolvidos utilizando uma combinação de *Python* e *Django*. O *Python* é reconhecido por sua versatilidade e pelas poderosas frameworks de análise de dados. Por outro lado, o *Django* foi escolhido não apenas pelo desenvolvimento do *backend* devido à sua robustez e recursos de segurança integrados, mas também por facilitar a criação de componentes interativos da interface de usuário, como formulários de login e registro, aproveitando suas ferramentas de autenticação bem testadas e seguras [98]. A separação entre *backend* e *frontend* pode oferecer benefícios específicos em termos de flexibilidade, desempenho e especialização, a escolha de utilizar *Django* para ambos os aspectos do desenvolvimento foi guiada por considerações pragmáticas de eficiência, segurança e simplicidade no processo de desenvolvimento.

A interface do usuário, incluindo páginas que vão além do escopo de autenticação, foi adicionalmente enriquecida com *HTML*, *Bootstrap* e *JavaScript*. Essa combinação promove uma experiência de usuário responsiva e intuitiva em diversos dispositivos. A usabilidade, um componente crucial para a aceitação de sistemas de *e-Health* pelos usuários, beneficia-se enormemente de um design centrado no usuário, que é vital para o sucesso desses sistemas [99].

Para a integração das tecnologias selecionadas foi necessário assegurar a interoperabilidade entre todas as ferramentas e tecnologias selecionadas, a fim de formar uma combinação coesa de ferramentas tecnológicas. Isso incluiu a integração do dispositivo vestível Garmin com o banco de dados *InfluxDB*, garantindo a transferência dos dados. A capacidade de integrar diferentes sistemas e plataformas é fundamental para soluções de *e-Health* eficazes [100], [101].

O desempenho do sistema e a qualidade da experiência do usuário foram avaliados e as tecnologias *front-end* foram escolhidas para garantir um carregamento eficiente de uma interface intuitiva, facilitando o engajamento do usuário com a plataforma [102]. Esta abordagem pretende que o sistema não apenas colete e processe dados com precisão, mas também os apresente de forma eficaz e acessível, promovendo uma experiência do usuário que encoraja a adoção e o uso da plataforma *e-Health*.

3.2 Arquitetura do Sistema

A arquitetura do sistema proposto foi projetada para ser uma solução integrada de *e-Health*, que utiliza a interação entre o usuário e o dispositivo vestível. Como pode ser visto na Figura 3.3, a arquitetura compreende os processos de recolha de dados, avaliação, decisão e ação para um usuário, mostrando o núcleo processador do sistema. Estudos demonstram a eficácia de sistemas integrados de *e-Health* que utilizam dispositivos vestíveis para recolha e análise de dados, enfatizando a importância de uma arquitetura robusta para esses sistemas [88] [103]. Além disso, inicialmente se foi pensado em integrar um sistema doméstico a esse mecanismo de funcionamento, que permitiria o controle de outros

parâmetros para o usuário, como luminosidade e temperatura, mas devido a não ter sido possível o acesso a tal ambiente controlado, essa implementação foi deixada de lado e sugerida para trabalhos futuros.




Figura 3.3: Diagrama ilustrativo do mecanismo central da arquitetura do sistema de *e-Health*.

A representação esquemática delinea o mecanismo operacional de um sistema de e-Health centrado no usuário, enfatizando a integração e análise de dados para a gestão da saúde. O usuário é o núcleo de interação, fornecendo dados essenciais por meio de um dispositivo vestível, que monitora variáveis fisiológicas e comportamentais. Os dados são coletados e submetidos a um processo de validação. Posteriormente, através da aplicação de algoritmos, o módulo analítico avalia os dados, identificando padrões e potenciais alertas de saúde. As decisões resultantes são formuladas com base nesta análise, direcionando ações específicas no ambiente do usuário, como recomendações personalizadas para promover o bem-estar.

O processo é caracterizado por uma dinâmica cíclica, onde a coleta e análise de dados resultam em intervenções que visam promover a saúde e o bem-estar, demonstrando a aplicação prática dos dados na gestão da saúde.

A escolha de arquitetura para este sistema, foi de uma arquitetura modular, que reflete uma abordagem estratégica que divide o sistema em módulos menores e independentes, cada um com sua função específica. Estes módulos se comunicam entre si através de interfaces bem definidas, o que contribui para uma maior flexibilidade na atualização e manutenção do sistema. Mudanças em um módulo tendem a ter impacto limitado sobre o resto do sistema, facilitando a gestão de atualizações e correções.

Além disso, a natureza modular do sistema favorece a escalabilidade e a reutilização

de código. Isso permite que novas funcionalidades sejam adicionadas de maneira mais eficiente, otimizando o uso de recursos e tempo de desenvolvimento. A possibilidade de desenvolver módulos de forma independente e em paralelo acelera o processo de desenvolvimento, tornando-o mais ágil e responsivo às mudanças. Importante destacar também que a arquitetura modular aumenta a robustez do sistema. Em caso de falhas, estas podem ser isoladas em módulos específicos, minimizando os riscos de falhas sistêmicas e mantendo a estabilidade geral do sistema [104].

As funções que viabilizam o funcionamento do sistema são feitas através do *Python*. Elas permitem a recolha de dados, o armazenamento eficiente no *InfluxDB*, a modelagem de métricas de saúde e a interação do usuário com o sistema através de uma interface web. A utilização do *Python*, uma linguagem de programação de alto nível com vasta biblioteca de análise de dados e suporte para operações de rede, permite a implementação eficaz de funcionalidades, proporcionando eficiência no processamento de dados e a precisão na geração de recomendações de saúde personalizadas [105], [106]. A seguir serão explicados em detalhes cada um dos módulos específicos desta arquitetura.

3.2.1 Recolha de Dados

A recolha de dados constitui o ponto de partida no sistema *e-Health*, sendo um passo crítico na cadeia de gestão da saúde digital. Como apresentado na Figura 3.4, a recolha de dados começa com a interação entre o dispositivo vestível e a *Application Programming Interface (API)*. A API desempenha um papel essencial, atuando como um intermediário que solicita e recebe dados fisiológicos e de atividade do dispositivo, tais como frequência cardíaca e contagem de passos.




Figura 3.4: Processo de recolha de dados no sistema *e-Health*.

As *Application Programming Interfaces (APIs)* são fundamentais no ecossistema de saúde digital, atuando como pontes entre dispositivos vestíveis e sistemas de análise de dados, permitindo a coleta automatizada e em tempo real de dados fisiológicos e de atividade. A API da Garmin, por exemplo, oferece acesso programático a uma riqueza de dados gerados por seus dispositivos, facilitando a integração desses dados em aplicações de e-Health. Esta abordagem automatizada contrasta com a alternativa de exportar manualmente todos os dados para um arquivo e, em seguida, baixar esse arquivo, como descrito na página de suporte da Garmin [107]. Embora a exportação de dados ofereça uma via para acessar informações de forma agregada, essa metodologia não foi adotada neste estudo por várias razões.

Primeiramente, a coleta de dados via API proporciona uma integração mais fluida e contínua, essencial para o monitoramento em tempo real e a análise longitudinal dos dados de saúde, o que é crítico para pesquisas e aplicações que dependem da atualidade e da precisão dos dados. Além disso, a abordagem automatizada através da API minimiza a necessidade de intervenção manual, reduzindo o potencial para erros humanos e economizando tempo significativo que, de outra forma, seria necessário para o processo de exportação e download de dados. A automatização também permite a coleta de dados em intervalos regulares sem a necessidade de ação por parte do usuário, garantindo uma coleta de dados mais consistente e confiável.

Por outro lado, a exportação manual e o download de arquivos de dados representam uma solução menos eficiente e mais propensa a inconsistências, particularmente em contextos onde os dados são volumosos e a coleta contínua é necessária. Além disso, essa abordagem pode limitar a capacidade de realizar análises em tempo real ou de responder prontamente a percepções derivadas dos dados. Em suma, a escolha de não utilizar a exportação manual de dados em favor da integração direta via API foi guiada pela necessidade de eficiência operacional, precisão dos dados e a possibilidade de análise em tempo real, elementos cruciais para o sucesso de sistemas avançados de *e-Health*.

A recolha de dados em sistemas *e-e-Health* depende essencialmente da interação com diversas APIs de fabricantes de dispositivos vestíveis, como Apple, Samsung, Fitbit e

Garmin. Cada fabricante oferece sua própria API, facilitando a integração de dados de diferentes dispositivos em sistemas de saúde digital. No caso específico da Garmin, utilizado no estudo, os dados não foram recolhidos diretamente do relógio, mas sim através dos dados em *Cloud* da Garmin Connect. Esta abordagem destaca a importância da API do Garmin Connect para acessar os dados, pois ela serve como a ponte necessária entre o dispositivo e os sistemas de saúde que buscam analisar os dados fisiológicos de um determinado usuário, garantindo a compatibilidade e a integração eficaz dos dados no ecossistema digital de saúde.

O processo de interação com a API do Garmin Connect é detalhado através do envio de requisições específicas para o servidor, que prontamente responde fornecendo os dados de saúde dos usuários em um formato estruturado e acessível. No sistema do estudo, a arquitetura de recolha funciona quando o usuário acessa a página da interface, esse acesso faz a requisição ao Garmin Connect, fornecendo os dados para o sistema. Este mecanismo de comunicação estabelece uma ponte vital entre o sistema *e-Health* e os serviços externos, permitindo a integração de dados de saúde em tempo real. A Figura 3.5 ilustra claramente este fluxo bidirecional de informações, que é fundamental para o monitoramento eficaz e contínuo da saúde dos indivíduos.

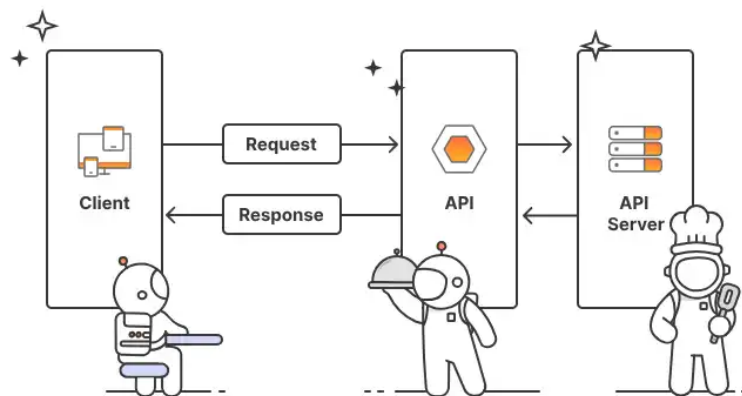


Figura 3.5: Funcionamento de uma API [108].

Durante os testes, observou-se que o cliente Garmin bloqueia as requisições de dados do Garmin Connect quando muitas chamadas são feitas em um curto período de tempo. Para

garantir a eficiência operacional do sistema *e-Health* e evitar sobrecargas, implementaram-se medidas para controlar a frequência das chamadas à API da Garmin.

Estabeleceu-se uma restrição de tempo, se um usuário tentar acessar os dados em menos de 10 minutos após a última atualização, receberá uma mensagem informando que novas requisições não são possíveis até que o intervalo de tempo permitido tenha transcorrido. Esse controle tem como objetivo minimizar o risco de erros, como o erro 429, que ocorre ao exceder o limite de chamadas permitidas em um dado intervalo. Servidores web comumente adotam essa prática para manter a qualidade do serviço e a disponibilidade do sistema [109]. A Figura 3.6 exemplifica a mensagem de erro recebida ao ultrapassar o limite de chamadas. Além disso, recomendou-se ao usuário que fosse evitado fazer requisições muitas vezes durante o dia.

```
Erro ao conectar: Error in request: 429 Client Error: Too Many Requests for url: https://sso.garmin.com/sso/signin?id=gauth-widget&embedWidget=true&gauthHost=https%3A%2F%2Fsso.garmin.com%2F%2Fsso%2Fembed&service=https%3A%2F%2Fsso.garmin.com%2F%2Fsso%2Fembed&source=https%3A%2F%2Fsso.garmin.com%2F%2Fsso%2Fembed&redirectAfterAccountLoginUrl=https%3A%2F%2Fsso.garmin.com%2F%2Fsso%2Fembed&redirectAfterAccountCreationUrl=https%3A%2F%2Fsso.garmin.com%2F%2Fsso%2Fembed
Internal Server Error: /user/
```

Figura 3.6: Ocorrência de erro por muitas chamadas em curto período.

Após a obtenção dos dados do servidor, eles são então encaminhados para serem armazenados numa base de dados, assegurando que cada pedaço de informação seja mantido de forma segura e estruturada. Esta etapa é fundamental para garantir que os dados estejam disponíveis para análise e avaliação futuras, mantendo a integridade, precisão e privacidade das informações do usuário.

Por fim, após o armazenamento, os dados são prontamente disponibilizados para a etapa de avaliação, onde são analisados e processados para informar decisões relacionadas à saúde do usuário. Este fluxo de informações é desenhado para permitir uma análise de saúde contínua e em tempo real, proporcionando a base para intervenções de saúde preditivas e personalizadas no ecossistema *e-Health*.

3.2.2 Avaliação dos Dados

A fase de avaliação e interpretação dos dados, capturados pelo sistema *e-Health*, desempenha um papel crucial no processo decisório, como demonstrado na Figura 3.7. Essa etapa essencial prepara os dados para uso subsequente, refinando-os para assegurar que estejam adequadamente prontos para aplicação nos módulos subsequentes.




Figura 3.7: Processo de avaliação dos dados no sistema *e-Health*.

Inicia-se o processo com o "Processamento dos Dados Armazenados", onde os dados são filtrados, limpos e transformados utilizando algoritmos em *Python*. Esta etapa é projetada para estruturar os dados de forma a facilitar a extração de percepções e a síntese de pontuações de saúde.

Na etapa subsequente, "Geração de Pontuações", os dados processados são utilizados para calcular pontuações quantitativas que refletem o estado de saúde e bem-estar do usuário. Estas pontuações são derivadas com base em modelos preditivos e características do usuário, fornecendo uma representação numérica do bem-estar físico e emocional do utilizador. As pontuações resultantes são cruciais para a identificação de desvios em relação aos padrões de saúde esperados e para a sinalização de alertas de saúde quando necessário.

Após a geração das pontuações, os dados são "Enviados para o Banco de Dados", onde são armazenados de maneira segura e estruturada. Este repositório de dados serve como uma interface central para todas as informações de saúde relacionadas ao usuário, permitindo o acesso e a recuperação eficiente para análises futuras e tomadas de decisão.

O passo final é ir para o próximo bloco da arquitetura, que será a tomada de decisão sobre o que fazer com os dados avaliados. Este fluxo de trabalho representa um ciclo iterativo e contínuo de melhoria e refinamento, onde o *feedback* do usuário e as descobertas emergentes podem retroalimentar o sistema, visando a otimização contínua dos algoritmos

e a precisão das recomendações.

3.2.3 Decisão

O mecanismo de tomada de decisão do sistema *e-Health*, ilustrado na Figura 3.8, é a fase conclusiva do processo de monitoramento de saúde, onde as pontuações obtidas são utilizadas para orientar intervenções ou alterações comportamentais. Este mecanismo engloba várias etapas sequenciais que convertem os dados em ações práticas.




Figura 3.8: Processo decisório no sistema *e-Health*.

A primeira etapa é a "Leitura das Pontuações do Banco de Dados", onde o sistema consulta o repositório de dados central para extrair as pontuações de saúde mais recentes do usuário. Esta operação é vital para assegurar que as decisões se baseiem nos dados mais atualizados.

Posteriormente, no estágio de "Categorização das Pontuações", as pontuações são avaliadas contra limiares predefinidos e categorizadas como 'Bom', 'Médio' ou 'Ruim'. Este processo de categorização é crucial para a estratificação do risco e a priorização de ações. Os limiares são ajustados de acordo com o contexto e as necessidades específicas do usuário.

Este fluxograma de decisão termina com a definição de "Ir para Ação", que será onde as recomendações ou alertas são comunicados ao usuário. Esta abordagem estruturada para a tomada de decisão enfatiza a importância de dados acionáveis e a necessidade de um sistema que responda dinamicamente às variações na saúde do usuário, promovendo uma gestão de saúde personalizada.

3.2.4 Ação no Ambiente

A etapa final no ciclo do sistema *e-Health* é a implementação de ações no ambiente do usuário, conforme detalhado na Figura 3.9. Este estágio é crucial, pois é onde as decisões tomadas são convertidas em intervenções práticas que impactam diretamente a saúde e o bem-estar do usuário.

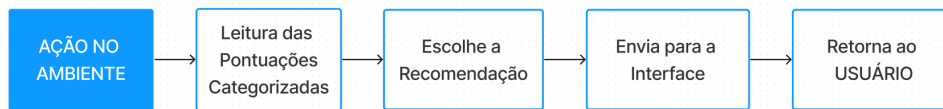


Figura 3.9: Ações no ambiente baseadas nas decisões do sistema *e-Health*.

Inicialmente, o sistema realiza a "Leitura das Pontuações", acessando as mais recentes avaliações de saúde do usuário a partir do banco de dados. Essa leitura é essencial para assegurar que as ações recomendadas estejam sincronizadas com o estado atual de saúde do usuário.

Em seguida, na fase de "Escolha da Recomendação", o sistema utiliza um conjunto de regras de decisão pré definidas. Isso pode incluir conselhos para fazer uma atividade, escutar uma música ou técnicas de gestão de estresse, entre outros. Se uma pontuação for categorizada como 'Ruim', por exemplo, o sistema indica na interface do usuário, sugerindo a necessidade de uma intervenção. Pontuações 'Médias' podem resultar em recomendações para modificar comportamentos de saúde ou em ajustes finos das estratégias de cuidado. Para pontuações consideradas 'Boas', o sistema pode reforçar a manutenção das práticas atuais de saúde e bem-estar.

Uma vez selecionadas, as recomendações são "Enviadas para a Interface" do usuário através de uma interface web. A interface de usuário é meticulosamente projetada para garantir que as comunicações sejam intuitivas e facilmente compreendidas, maximizando assim as chances de adesão às recomendações.

O processo conclui com o "Retorno ao Usuário", onde o indivíduo recebe as recomendações e é encorajado a tomar ações concretas. Isso completa o ciclo de *feedback* do sistema *e-Health*, onde o monitoramento contínuo, a análise de dados e as intervenções

recomendadas interagem para promover o bem-estar do usuário. A eficácia desta etapa é fundamental para o sucesso do sistema, pois é a aplicação prática das análises de saúde que leva a melhorias mensuráveis no bem-estar do usuário.

3.3 Quantificação de Estados Emocionais

Este estudo aborda a complexidade de quantificar estados emocionais como tristeza, estresse e ansiedade no contexto de *e-Health*, utilizando uma metodologia que integra dados fisiológicos obtidos pelo dispositivo vestível com o *feedback* do usuário. Através da análise desses dados por algoritmos específicos, este trabalho visa discernir padrões que refletem os estados emocionais, traduzindo-os em pontuações de 0 a 100. Na escala da pontuação, 100 indica o estado emocional mais positivo, enquanto 0 reflete o mais negativo. Este sistema de pontuação, fundamentado em métricas como frequência cardíaca e qualidade do sono atividade física apoia-se na literatura que estabelece a relação destas com os estados psicológicos [110]–[114].

A implementação de pontuações individuais para cada métrica permite ao sistema *e-Health* elaborar recomendações de saúde personalizadas, categorizadas como ruim, médio ou bom. Estas são baseadas na análise dos dados coletados, processados por *scripts* em *Python*, melhorando a precisão e relevância das intervenções de saúde sugeridas [59], [115]. A seleção dessas métricas foi também influenciada pela sua disponibilidade na maioria dos dispositivos vestíveis atuais, o que reforça a aplicabilidade e a relevância do estudo no desenvolvimento de soluções de saúde personalizadas e adaptadas às necessidades individuais [110], [112], [116]–[120]. Dessa forma, este estudo propõe uma abordagem metódica para a quantificação de estados emocionais.

3.4 Sistema de Recomendações

Com base nas pontuações geradas pelos modelos de análise, o sistema automaticamente cria recomendações customizadas para cada indivíduo. Por exemplo, uma alta pontuação

em tristeza sugere a manutenção de práticas de saúde vigentes, incentivando atitudes positivas, enquanto pontuações mais baixas em tristeza indicam a necessidade de alterações, como ouvir músicas mais alegres. Em outro cenário, uma pontuação reduzida em atividade física resulta em recomendações para promover o movimento, sugerindo atividades como caminhadas ou exercícios leves.

O sistema de recomendações é um elemento transformador no ecossistema de *e-Health*, desenhado para empoderar usuários e profissionais de saúde com percepções orientadas para ação. Integrando os modelos de humor desenvolvidos, o sistema usa as pontuações calculadas para gerar recomendações personalizadas que visam promover o bem-estar emocional e um estilo de vida saudável. Essa abordagem detalhada e personalizada resulta em um leque mais amplo de recomendações, proporcionando suporte direcionado para cada área específica da saúde do usuário [121]–[124].

Inicialmente, as recomendações se basearam na literatura especializada e, acima de tudo, na adequação ao usuário do sistema. Elas são aplicadas conforme as pontuações obtidas por meio dos *script* em *Python*, levando em consideração o nível atual de cada métrica associada ao usuário. A incorporação de rotinas regulares e momentos de lazer pode atuar como um amortecedor contra o estresse, promovendo recursos psicossociais e melhorando o bem-estar a longo prazo [125]. Além disso, atividades de lazer foram associadas a melhorias no humor, reduções no estresse e na frequência cardíaca, sugerindo vários mecanismos pelos quais o lazer é eficaz para melhorar a saúde e o bem-estar [126]. Outro fator importante é que foram feitas mais de uma recomendação para cada nível de cada métricas, estas eram selecionadas aleatoriamente pelo sistema, visando uma diversificação na hora da sugestão ao usuário, minimizando assim a falta de interesse do mesmo em realizar as indicações propostas. Para simplificar a explicação e o desenvolvimento do capítulo, será mostrada apenas uma das opções de recomendações.

As pontuações de estresse podem ser categorizadas em três níveis: baixo, médio e alto. Uma pontuação baixa, geralmente entre 0 e 40, pode indicar um estado de baixo estresse, onde são recomendadas práticas de autocuidado, como uma caminhada ao ar livre ou uma sessão de exercícios leves para manter o bem-estar. No nível médio, com pontuações entre

41 e 60, sugere-se uma atenção moderada aos efeitos do estresse, incentivando atividades que possam aliviar a tensão, como meditação ou uma pausa para o café. Pontuações altas, entre 61 e 100, denotam níveis elevados de estresse, onde é crucial manter práticas saudáveis e buscar apoio profissional se necessário. A Tabela 3.2 de recomendação para o usuário é exibida a seguir.

Pontuação de Estresse	Intervalo	Recomendação
Alta	61-100	Você parece estar com os níveis de estresse bem controlados. Mantenha as boas práticas, como uma rotina regular e momentos de lazer.
Média	41-60	Você pode estar sentindo os efeitos do estresse. Que tal uma caminhada ao ar livre ou uma sessão de exercícios leves para aliviar a tensão?
Baixa	0-40	É importante cuidar de si mesmo quando o estresse está muito alto. Práticas de auto-cuidado e, se necessário, buscar apoio profissional são essenciais.

Tabela 3.2: Recomendações baseadas no nível de estresse.

A meditação e o yoga são práticas com evidências substanciais de reduzir a ansiedade e o estresse, promovendo uma sensação de calma e controle, a meditação pode ser eficaz na redução da ansiedade, especialmente quando praticada regularmente [127]. O yoga, por sua vez, tem sido associado à melhoria dos níveis de ansiedade através de um efeito benéfico sobre o sistema nervoso autônomo e a regulação do eixo hipotálamo-pituitária-adrenal, conforme demonstrado em estudos que exploram sua influência no bem-estar psicológico [128].

A categorização das pontuações de ansiedade, assim como as de estresse, pode ser dividida em baixa, média e alta. Para pontuações mais baixas (0-50), atividades de relaxamento como a meditação guiada podem ser recomendadas para acalmar a mente. Links clicáveis com recursos ou vídeos de meditação podem ser incluídos para facilitar o acesso do usuário a essas práticas. Para níveis moderados de ansiedade (51-80), sugere-se a prática de meditação ou yoga para encontrar equilíbrio e manter a calma. Uma pausa ativa, como levantar-se para pegar água, também pode ser útil para desviar brevemente a atenção das fontes de ansiedade e ajudar a redefinir o foco mental. Para pontuações

altas de ansiedade (81-100), é crucial continuar com as práticas que têm sido úteis para o usuário, reforçando a importância da continuidade e consistência no manejo da ansiedade. As recomendações podem ser vistas na Tabela 3.3 abaixo na interface de administração do *Django*.

Pontuação de Ansiedade	Intervalo	Recomendação
Alta	81-100	Você está gerenciando bem a sua ansiedade. Continue com as práticas que têm ajudado você a se manter calmo e ativo durante o dia.
Média	51-80	Você parece ter um nível moderado de ansiedade. Considere praticar yoga para encontrar equilíbrio.
Baixa	0-50	A ansiedade parece estar alta. Experimente estas atividades de relaxamento e meditação para ajudar a acalmar a mente. > Link <

Tabela 3.3: Recomendações baseadas no nível de ansiedade.

As recomendações para o gerenciamento do estresse na imagem refletem uma abordagem baseada em evidências que inclui atividades físicas leves, cuidados pessoais, técnicas de relaxamento e práticas de atenção plena. A prática de exercícios físicos, como caminhadas, foi associada à melhoria do humor e à redução da ansiedade e do estresse, em parte devido ao aumento dos níveis de neurotransmissores que promovem o bem-estar, como as endorfinas. Além disso, a música tem sido utilizada como uma intervenção terapêutica eficaz para elevar o humor durante o tratamento agudo do acidente vascular cerebral [129], [130].

As categorizações de pontuações para o estresse, demarcadas como 0-40 (ruim), 41-80 (médio) e 81-100 (bom), servem como um indicador quantitativo do estado emocional do usuário, baseadas em parâmetros fisiológicos e comportamentais capturados pelo dispositivo vestível. A categorização "**ruim**" identifica uma alta incidência de sintomas relacionados ao estresse, sugerindo a necessidade de intervenções imediatas como práticas de auto-cuidado ou busca por suporte profissional. A faixa "**média**" indica um nível gerenciável de estresse, onde práticas preventivas e estratégias de gestão, como atividades

relaxantes e atenção plena, são recomendadas para evitar o agravamento do estado emocional. Por fim, a classificação "boa" reflete um estado de baixo estresse, em que o indivíduo é encorajado a continuar com as práticas positivas de manutenção da saúde emocional e física. As recomendações visam otimizar a eficácia na promoção do bem-estar por meio de intervenções personalizadas, as quais são fundamentadas em avaliações precisas do estado emocional [131]. A Tabela 3.4 mostra como seriam essas recomendações.

Pontuação de Tristeza	Intervalo	Recomendação
Alta	81-100	Sua pontuação de tristeza está ótima! Continue a cultivar a positividade em sua vida.
Média	41-80	Você está indo bem, mas há sempre espaço para melhorar. Tire um tempo para si mesmo e faça algo que você ama. Experimente fazer um café!
Baixa	0-40	Parece que você pode estar se sentindo um pouco para baixo. Ouça essas músicas alegres para levantar seu ânimo. > Link <

Tabela 3.4: Recomendações baseadas no nível de tristeza.

A seguir, serão discutidas as recomendações associadas às métricas capturadas pelo relógio inteligente. Estas métricas são essenciais para compreender e avaliar os níveis de tristeza, ansiedade e estresse dos indivíduos. A estratégia adotada envolve melhorar cada uma dessas métricas de maneira isolada, o que se espera, por sua vez, que contribua positivamente para o aprimoramento das demais. Ao focar em cada métrica separadamente, é possível obter uma compreensão mais clara de como cada uma influencia o estado emocional do usuário e como, em conjunto, elas interagem para afetar o bem-estar geral.

As recomendações relacionadas à frequência cardíaca apresentadas fornecem percepções que destacam diferentes intervenções dependendo das faixas de pontuação categorizadas como ruim (0-50), média (51-80) e boa (81-100). Para pontuações de frequência cardíaca na faixa 'boa', sugere-se a manutenção de rotinas saudáveis como um indicativo de uma condição cardíaca ideal, refletindo um estado de saúde e relaxamento. Existe uma associação positiva entre uma frequência cardíaca estável e níveis reduzidos de estresse, com um funcionamento saudável do sistema cardiovascular [132].

Para pontuações 'média' de frequência cardíaca, sugere-se relaxamento via atividades leves ou música, visando equilíbrio emocional e saúde cardíaca [133]. Em casos de pontuações na faixa 'baixa', que podem sinalizar irregularidades, recomenda-se técnicas de respiração e consulta médica para prevenir riscos cardiovasculares causada por variabilidade cardíaca reduzida a estresse elevado [134]. Detalhes dessas recomendações estão na Tabela 3.5.

Pontuação de Frequência Cardíaca	Intervalo	Recomendação
Alta	81-100	Sua frequência cardíaca está em uma faixa saudável, indicando bom nível de saúde e relaxamento. Continue seguindo um estilo de vida saudável! E se estivesse se exercitando na última hora, continue assim!
Média	51-80	Sua frequência cardíaca mostra que você pode estar sentindo alguma mudança de humor. Tente relaxar com atividades leves ou ouvindo música que goste.
Baixa	0-50	Foi detectado uma sequência de leituras cardíacas irregulares ou elevadas. Recomendamos que você pratique técnicas de respiração calmantes e, se essas leituras forem comuns, consulte um médico.

Tabela 3.5: Recomendações baseadas no nível de frequência cardíaca.

Estas recomendações se baseiam no reconhecimento de que a frequência cardíaca é um reflexo não apenas do estado físico, mas também do estado emocional e dos níveis de estresse, tornando-a um indicador valioso para intervenções direcionadas e prevenção de condições de saúde adversas [135].

Para pontuações de atividade 'boas' (100), a continuação de um estilo de vida ativo é encorajada, o que é corroborado por pesquisas indicando que altos níveis de atividade física estão associados com melhor saúde física e redução de risco para doenças crônicas [136]. Na faixa de atividade 'média' (51-99), sugere-se a adoção de melhorias, tais como agendar sessões de exercícios com amigos. Esta estratégia tem se mostrado eficaz não apenas para elevar os níveis de atividade física, mas também para ampliar a motivação e o comprometimento com o exercício, devido ao seu aspecto social [137].

Para pontuações 'ruins' (0-50), incentiva-se a adoção de atividades imediatas, como caminhadas rápidas ou sessões de exercícios em casa. Essas ações imediatas podem ajudar a superar o sedentarismo e iniciar um ciclo positivo de aumento da atividade física, conforme evidenciado em estudos que demonstram o impacto de pequenas mudanças no comportamento sobre a saúde em geral [138]. Pode-se observar as recomendações sugeridas para a atividade, com base nas pontuações, na Tabela 3.6.

Pontuação de Atividade	Intervalo	Recomendação
Alta	91-100	Ótimo trabalho mantendo-se ativo! Continue assim!
Média	51-90	Você está ativo, mas ainda pode melhorar. Que tal marcar uma sessão de exercícios com um amigo?
Baixa	0-50	Parece que você está abaixo da meta de atividade. Vamos tentar uma caminhada rápida ou uma curta sessão de exercícios em casa?

Tabela 3.6: Recomendações baseadas no nível de atividade.

Para pontuações de sono 'boas' (81-100), indica-se manter boas práticas. A continuação de uma rotina de sono consistente é recomendada, o que é apoiado por estudos que encontraram associações positivas entre uma boa higiene do sono e vários aspectos da saúde física e mental [136], [139].

Para a faixa de sono 'média' (61-80), sugestões de melhorias incluem evitar telas brilhantes antes de dormir. Pesquisas indicam que a exposição à luz azul de dispositivos eletrônicos antes de dormir pode afetar negativamente a qualidade do sono, levando a uma saúde mental e física abaixo do ideal [140], [141].

Para pontuações de sono 'ruins' (0-60), é incentivada a adoção de uma rotina relaxante antes de dormir e a criação de um ambiente adequado para o sono. Estudos demonstram que a qualidade do sono insatisfatória pode estar associada a uma variedade de problemas de saúde, incluindo um risco aumentado de doenças crônicas e problemas de saúde mental [142], [143]. A Tabela 3.7 representa o administrador do *Django* para as recomendações de qualidade do sono.

Pontuação de Qualidade do Sono	Intervalo	Recomendação
Alta	81-100	Parabéns pelo bom sono! Continue mantendo uma rotina de sono consistente.
Média	61-80	Seu sono está em um nível médio. Tente evitar telas brilhantes antes de dormir.
Baixa	0-60	Seu sono parece estar com baixa qualidade. Considere estabelecer uma rotina relaxante antes de dormir e criar um ambiente adequado para o sono.

Tabela 3.7: Recomendações baseadas no nível de qualidade do sono.

As recomendações são validadas por meio de um processo contínuo que inclui testes e *feedback* do usuário. Este ciclo de *feedback* é essencial para garantir que as recomendações permaneçam precisas e relevantes, permitindo ajustes e melhorias contínuas. O sistema está configurado para adaptar-se às necessidades individuais do usuário, refletindo a abordagem centrada no usuário que é um pilar fundamental da nossa metodologia [144]–[146].

O aperfeiçoamento do sistema de recomendações destaca-se como um elemento transformador no nosso sistema de *e-Health*. Este sistema avançado integra os modelos de humor desenvolvidos para criar intervenções personalizadas que promovem o bem-estar emocional e um estilo de vida saudável [147], [148].

Através da interface administrativa do *Django*, as recomendações são gerenciadas de forma eficiente e intuitiva. Os administradores do sistema podem atualizar ou modificar as recomendações sem necessidade de conhecimentos avançados de programação, garantindo que o sistema permaneça adaptável às necessidades em constante mudança dos usuários [149], [150]. A capacidade de alterar facilmente o conteúdo das recomendações demonstra a flexibilidade do sistema. Esta adaptabilidade é crucial para atender às diferentes populações de usuários, com suas preferências e restrições específicas, garantindo que o sistema seja inclusivo e relevante para todos [151], [152]. Abaixo, na Figura 3.10, é possível observar como seria uma visão ampliada da interface administrativa do *Django*, onde estão armazenadas essas recomendações.

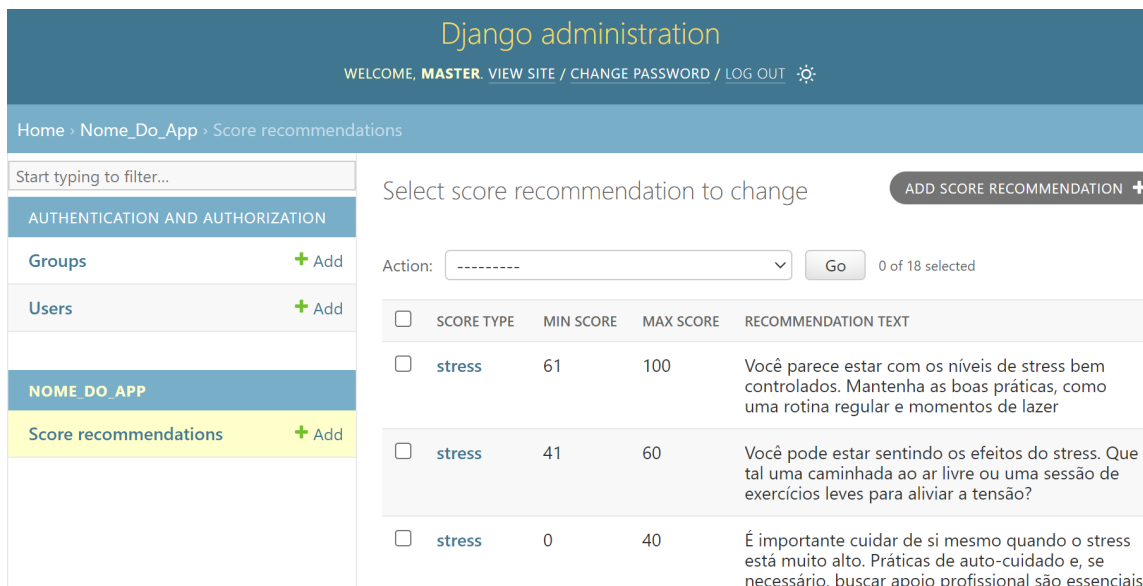


Figura 3.10: Interface com as Recomendações no Administrador *Django*.

O processo de validação das recomendações é contínuo, fundamentado no *feedback* do usuário voluntário, e nas melhores práticas emergentes na literatura de saúde. Este processo assegura que as recomendações se mantenham atualizadas com os avanços científicos mais recentes e as necessidades em evolução dos usuários [153], [154].

3.5 *Feedback* e Iteração

O ciclo de *feedback* e iteração é um componente crítico do sistema *e-Health* proposto, possibilitando ajustes personalizados baseados nas experiências e necessidades dos usuários [155], [156]. Foi implementado um mecanismo de *feedback* interativo, projetado para capturar respostas emocionais diretamente dos usuários, fundamental para a personalização do sistema *e-Health*.

Este mecanismo interativo permite que os usuários registrem suas experiências emocionais em tempo real por meio de uma interface gráfica projetada para esse fim, garantindo que as recomendações e análises comportamentais geradas pelo sistema se alinhem com as percepções subjetivas de cada indivíduo [157], [158].

O sistema é ajustado e refinado com base no *auto-feedback*, adotando uma metodologia

de design iterativo. Isso permite que o desenvolvedor ajuste continuamente o sistema com base na própria utilização e experiência, otimizando a personalização e eficácia das recomendações. Estudos mostram que a abordagem centrada no usuário e o design iterativo são fundamentais para o sucesso de sistemas de *e-Health*, pois garantem que o sistema atenda às necessidades reais dos usuários [159], [160].

Através de uma metodologia iterativa e centrada no usuário, o sistema é constantemente aprimorado, garantindo que as recomendações e intervenções permaneçam relevantes e efetivas. Este processo assegura que o sistema atenda não apenas às necessidades do usuário, mas que também possa ser generalizado para atender a uma gama mais ampla de usuários. A literatura enfatiza a importância de uma abordagem de design iterativo e centrada no usuário para sistemas de *e-Health*, visando aprimoramentos contínuos e adaptabilidade [161], [162].

A Figura 3.11 abaixo ilustra o ciclo de *feedback* e iteração no contexto do sistema proposto. O diagrama destaca a centralidade do usuário, sublinhando o papel vital da sua interação e experiência no processo de calibração e melhoria contínua do sistema.

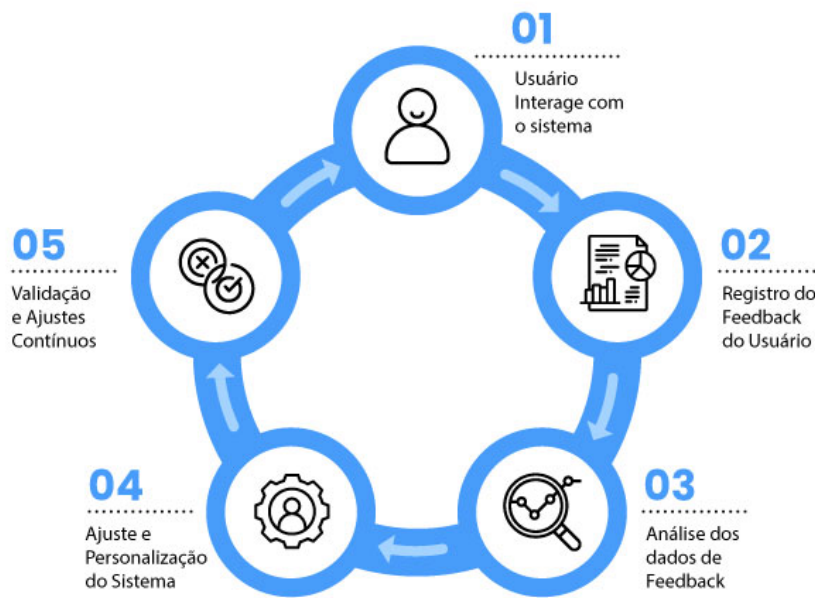


Figura 3.11: Ilustração do ciclo de *feedback* e iteração no sistema *e-Health*.

A validação e ajustes são realizados de forma contínua, com o usuário utilizando o sistema e sugerindo modificações conforme necessário. Este ciclo de validação e ajuste garante que o sistema seja personalizado para atender às necessidades específicas do utilizador, proporcionando uma experiência altamente personalizada e centrada no usuário. Estudos recentes destacam a eficácia dessa abordagem, enfatizando a importância de envolver ativamente os usuários no processo de desenvolvimento e aprimoramento de sistemas de *e-Health* [159], [160].

A inclusão do usuário voluntário como um caso de estudo inicial é fundamental, demonstrando a eficácia do design participativo e da co-criação. Este método coloca o usuário no coração do desenvolvimento do sistema, garantindo que as recomendações sejam adaptadas e responsivas às necessidades individuais do usuário.

Pesquisas recentes em design centrado no usuário em *e-Health* enfatizam a importância de envolver ativamente os usuários no processo de desenvolvimento. Estudos mostram que a colaboração direta com os usuários pode levar a uma maior aceitação do sistema, maior satisfação do usuário e melhores resultados de saúde. Além disso, a abordagem centrada no usuário pode auxiliar no desenvolvimento de interfaces mais intuitivas e na identificação de áreas-chave para melhorias e inovações no sistema [163], [113], [160], [164].

Este capítulo apresentou uma estrutura das soluções propostas para o desenvolvimento do sistema de *e-Health*, incorporando tanto a análise de dados quanto a funcionalidade de dispositivos vestíveis para avaliar e melhorar o bem-estar emocional dos usuários. Nas próximas sessões serão discutidas as implementações dessas soluções e os resultados obtidos através delas.

Capítulo 4

Desenvolvimento e Implementação

O desenvolvimento do sistema *e-Health* proposto neste trabalho consistiu na implementação das soluções e estruturas teóricas delineadas no Capítulo 3, atendendo a arquitetura geral proposta para a solução.

Um elemento vital no desenvolvimento foi a integração do *feedback* do usuário na definição das métricas e critérios adotados pelo sistema. A seleção de parâmetros para os cálculos, como aqueles associados à quantificação de atividades (ex.: passos), foi amplamente baseada nas impressões e interações do indivíduo. Mediante avaliações recorrentes, esses critérios foram calibrados para espelhar com maior fidelidade as variações observadas no bem-estar percebido. Esse processo colaborativo assegurou que o sistema se atentasse aos fundamentos teóricos, estando em consonância com as demandas e preferências concretas do usuário [165]. As seções seguintes irão detalhar como foram empregados os desenvolvimentos para realizar a solução proposta.

4.1 Gestão de Dados

A administração de dados é uma vertente crítica na arquitetura de sistemas *e-Health*, destacando-se pela atenção à segurança e à eficácia na manipulação de informações de saúde. A implementação de práticas apropriadas de gestão de dados é crucial, mesmo em um cenário onde somente tem-se um único usuário, estabelecer boas práticas desde o

início é determinante para uma expansão segura no futuro.

O banco de dados *InfluxDB* foi selecionado por suas vantagens no gerenciamento de grandes volumes de dados, especialmente pela sua habilidade de realizar consultas temporais avançadas, proporcionando uma análise de saúde em tempo real essencial para a funcionalidade do sistema *e-Health*. A configuração inicial do cliente *InfluxDB* no contexto do sistema é realizada através da integração com o *framework Django*, que é utilizado para o desenvolvimento web em Python. As configurações do cliente são definidas utilizando as informações armazenadas no *Django*, facilitando assim a conexão com o *InfluxDB*.

O processo de configuração compreende a definição de *'buckets'*, que são os recipientes de dados no *InfluxDB*, e políticas de retenção, que determinam o período de armazenamento dos dados antes de sua exclusão automática. A flexibilidade das políticas de retenção permite a manutenção dos dados sem prazo fixo de expiração, adaptando-se às exigências de conservação de dados a longo prazo. A seguir, um pseudocódigo ilustra o processo de configuração do cliente *InfluxDB*, que é a base para a gestão eficaz de dados no sistema *e-Health*.

Configuração do Cliente InfluxDB

```
1 Definir cliente InfluxDB com:  
2     URL do InfluxDB das configurações do Django  
3     Token de acesso do InfluxDB das configurações do Django  
4     Organização do InfluxDB das configurações do Django
```

4.2 Modelo de Recolha

4.2.1 Integração com Dispositivos Vestíveis e Armazenamento de Dados

A conexão com o dispositivo vestível é estabelecida através da API do fabricante, mesmo com suas limitações, permitindo a aquisição de dados fisiológicos do usuário. A função `fetch_garmin_data` estabelece uma conexão autenticada com a conta do usuário no serviço Garmin Connect, agindo como o ponto de partida para todas as interações com a API

do dispositivo. Essa função é projetada para criar um cliente Garmin, encapsulando as credenciais do usuário, tentando realizar o login para estabelecer uma sessão autenticada. É fundamental que a função inclua um tratamento de exceções adequado, assegurando que quaisquer erros sejam gerenciados de forma eficaz, evitando interrupções no sistema e fornecendo *feedback* claro ao usuário em caso de falha na conexão.

O pseudocódigo que segue serve para representar a estrutura lógica envolvida na conexão e autenticação com a API do Garmin, abstraindo detalhes de implementação específicos e mantendo a clareza do processo.

```

          Conexão com a API do Garmin
1  Função fetch_garmin_data(email, senha):
2      Inicialize o cliente Garmin com o email e a senha fornecidos
3      Tente:
4          Efetue login no cliente Garmin
5          Retorne o cliente Garmin se o login for bem-sucedido
6      Exceto em caso de erro:
7          Exiba a mensagem de erro
8          Retorne None para indicar falha na conexão
9  Fim da Função
```

A funcionalidade de armazenamento de dados é uma etapa subsequente e essencial na arquitetura do sistema *e-Health*, como indicado no bloco 'Armazenar em uma base de dados' do diagrama 3.4 de recolha de dados da Seção 3.2.1. A função `write_health_data` é fundamental neste contexto, pois é encarregada de transferir os dados fisiológicos coletados dos dispositivos vestíveis para o *InfluxDB*, o repositório de dados central.

Essa função manipula não apenas a transferência de dados, mas também a criação de pontos de dados dentro do banco de dados, que é um conceito chave no modelo de armazenamento do *InfluxDB*. Cada ponto de dados consiste em uma série de informações que são categorizadas em *tags* e *fields*.

As *tags* são utilizadas para indexar os dados, permitindo consultas eficientes e segmentação de dados, como por exemplo, pela identificação do usuário. Os *fields* armazenam as métricas fisiológicas em si, tais como passos, frequência cardíaca, padrões de sono e

níveis de estresse. O *timestamp* (carimbo de data e hora) é atribuído a cada ponto para registrar o momento exato da recolha de dados, o que é crucial para análises que dependem do contexto temporal. O pseudocódigo a seguir descreve, de forma generalizada, o processo pelo qual a função `write_health_data` cria os pontos de dados e os armazena no InfluxDB.

```

----- Armazenamento dos dados no Banco de dados -----
1  Função write_health_data(identificação do usuário, dados fisiológicos, timestamp):
2      Inicie a conexão com o InfluxDB utilizando as configurações especificadas
3      Crie um novo ponto de dados
4      Associe a identificação do usuário como uma tag ao ponto de dados
5      Insira os dados fisiológicos coletados como fields no ponto de dados
6      Defina o timestamp correspondente ao ponto de dados
7      Armazene o ponto de dados no InfluxDB
8      Encerre a conexão com o banco de dados
9  Fim da Função
```

4.3 Modelo de Avaliação

4.3.1 Avaliação dos dados de Sono

A função de consulta de sono extrai dados do Garmin Connect das diferentes fases do sono — profundo, leve, REM, e acordado — dentro de um intervalo estipulado, que se alinha ao ciclo habitual de sono do usuário. Essa extração é realizada por meio da linguagem de consulta *Flux* do *InfluxDB*, que filtra e recupera os últimos dados relevantes de cada fase do sono.

Os dados resultantes são agregados em um dicionário, onde cada chave corresponde a uma fase do sono e cada valor representa a duração dessa fase em minutos. Caso nenhum dado seja recuperado para uma fase específica, um valor de zero é atribuído, assegurando que todas as fases sejam representadas no dicionário. O pseudocódigo representando a lógica da função de consulta do sono é visto a seguir.

```

----- Processo obtenção de dados do sono -----
1  Função get_sleep_data(usuario, data):
```

```
2 Estabeleça o intervalo de consulta de 24 horas, iniciando às 23:00 da
3 data indicada
4 Prepare um dicionário para armazenar as durações das fases do sono
5
6 Para cada fase do sono ['profundo', 'leve', 'REM', 'acordado']:
7     Formule a consulta Flux para dados da fase de sono do 'usuario' na 'data'
8     Execute a consulta para obter o registro mais recente dentro do intervalo
9
10    Se obtiver resultados:
11        Insira a duração da fase no dicionário
12    Senão:
13        Insira zero como a duração para essa fase no dicionário
14
15    Devolva o dicionário com os valores do sono
16 Fim da Função
```

Cálculo da Pontuação de Sono

A função `calculate_sleep_score` é um elemento chave na avaliação da qualidade do sono, empregando dados de sono para gerar uma métrica quantitativa que reflete tanto a duração quanto a qualidade do sono do usuário. Este cálculo integra a duração das fases do sono e o tempo acordado, ponderando cada elemento para produzir uma pontuação final.

A pontuação de duração baseia-se na quantidade total de horas de sono, alinhada com as diretrizes de 7 a 8 horas de sono ótimo para adultos [166]. A pontuação varia conforme a duração do sono, com um sistema de pontuação que gradua a qualidade de acordo com o quão próximo ou distante o usuário está do intervalo ideal. A qualidade do sono, por outro lado, é avaliada pela proporção do tempo acordado em relação ao total, com uma pontuação decrescente para proporções maiores de despertares [167], [168].

Os pesos para duração e qualidade são definidos em 70% e 30%, respectivamente, baseados na importância relativa destas métricas para o bem-estar geral do usuário, conforme indicado pelo *feedback* voluntário. A pontuação final é então calculada, arredondada e

limitada a um máximo de 100, conforme visto na Seção 3.3, proporcionando uma escala padronizada para avaliação da qualidade do sono [169]. Abaixo segue o pseudocódigo para o cálculo da pontuação de sono.

```

          Cálculo da pontuação de qualidade do sono.
1  Função calculate_sleep_score(dados_sono):
2      Peso da Duração = 70%
3      Peso da Qualidade = 30%
4
5
6      Se dados_sono estiver vazio
7          Retorne Nulo
8
9      Converta os dados de sono em segundos
10     Calcule o total de segundos de sono
11     Converta o total de segundos de sono em horas
12
13     Determine a pontuação de duração do sono
14         Se entre 7 e 8 horas, atribua 100
15         Se entre 6 e 7 ou entre 8 e 9 horas, atribua 80
16         Caso contrário, atribua 50
17
18     Determine a pontuação de qualidade do sono
19         Se tempo acordado for menor que 10% do total, atribua 100
20         Se tempo acordado for menor que 20% do total, atribua 80
21         Caso contrário, atribua 50
22
23     Aplique os pesos à duração e qualidade do sono
24     Calcule a pontuação final do sono
25     Pontuação do sono = Peso da Duração*Duração do sono x Peso da
26     Qualidade*Qualidade do sono
27     Arredonde e limite a pontuação final a um máximo de 100
28
29     Retorne a pontuação final do sono
30 Fim da Função
```

4.3.2 Avaliação dos dados de Atividade

A função `get_steps_data` é essencial para a análise da atividade física dos usuários no sistema *e-Health*, concentrando-se na extração de dados sobre os passos dados, coletados pelo dispositivo Garmin e armazenados no *InfluxDB*. Este procedimento permite quantificar a atividade física realizada pelo usuário, proporcionando percepções valiosas sobre seu bem-estar e saúde geral.

Através de uma consulta ao *InfluxDB*, a função busca dados de passos para um usuário específico e uma data determinada, agregando o total de passos dados durante esse intervalo. Esse processo envolve somar todos os registros de passos para fornecer uma visão abrangente da atividade física do usuário. Para exemplificar o processo pelo qual a função `get_steps_data` opera, abaixo segue o pseudocódigo correspondente.

Consulta de dados de Atividade no InfluxDB.

```
1 Função get_steps_data(usuario, data):
2     Configure a consulta para extrair dados de passos do InfluxDB
3     Defina o intervalo de tempo e os filtros apropriados para o usuário específico
4
5     Realize a consulta ao InfluxDB
6     Inicie uma variável para o total acumulado de passos
7
8     Para cada resultado da consulta:
9         Some os valores de passos ao total acumulado
10
11     Retorne o total acumulado de passos
12 Fim da Função
```

Cálculo da Pontuação de Atividade:

A função `calculate_activity_score` é determinante para avaliar a atividade física dos usuários, especificamente através da análise do número total de passos dados. Esta função compara a contagem de passos do usuário com metas estabelecidas para atribuir uma pontuação de atividade, incentivando a adoção de um estilo de vida mais ativo. A pontuação varia em função da atividade realizada, com metas definidas que refletem níveis

de atividade física recomendados pela literatura científica.

A definição das metas de passos diários para a pontuação é fundamentada em dois limiares principais: uma meta média de 5.000 passos e uma meta alta de 8.000 passos. Embora a recomendação popular e amplamente divulgada de 10.000 passos por dia seja respaldada por evidências que indicam benefícios substanciais à saúde e bem-estar, adaptações são necessárias para refletir as limitações contextuais dos usuários. As metas ajustadas para 5.000 e 8.000 passos consideram as particularidades do usuário do estudo, reconhecendo que um objetivo de 8.000 passos por dia oferece um balanço realista entre os benefícios à saúde e a viabilidade prática, alinhando-se às capacidades e limitações individuais. Este ajuste na formulação e validação dos cálculos visa promover a atividade física de maneira sustentável e acessível, adaptando-se à realidade dos participantes do teste e potencializando os impactos positivos sobre a saúde e qualidade de vida [170]–[172].

Atender ou exceder a meta alta resulta em uma pontuação máxima, valorizando o esforço do usuário em manter um alto nível de atividade física [173]. Para passos entre as metas média e alta, a pontuação é ajustada proporcionalmente, incentivando progresso contínuo [174]. Abaixo da meta média, a pontuação é atribuída de maneira que encoraje o usuário a aumentar sua atividade para atingir pelo menos a meta média [175]. Para ilustrar como essa função opera dentro do sistema, apresentamos um pseudocódigo que reflete o processo de cálculo.

```

----- Função que calcula a pontuação da atividade. -----
1  Função calculate_activity_score(total_passos):
2      Se total_passos for maior ou igual a 8000:
3          Pontuação = 100
4      Senão, se total_passos for maior ou igual a 5000 e menor que 8000:
5          Pontuação = valor proporcional entre 50 e 100
6      Senão:
7          Pontuação = valor proporcional até 50
8
9      Retorne a pontuação
10 Fim da Função
```

4.3.3 Avaliação dos dados da Frequência Cardíaca

A função `get_heart_rate_data` acessa os dados de frequência cardíaca armazenados no *InfluxDB*, ela executa uma consulta *Flux* direcionada para extrair medições específicas do usuário em questão, assegurando a relevância e atualidade dos dados coletados. O resultado dessa operação é uma série de registros de frequência cardíaca, que são então organizados em uma lista de dicionários, cada um representando um ponto de dados com seu respectivo valor e carimbo de data/hora. Segue abaixo um pseudocódigo exemplificando a operação da função `get_heart_rate_data`.

———— Consulta de dados de Frequência Cardíaca no InfluxDB. ————

```
1 Função obter_dados_frequencia_cardiaca(usuario):
2
3     Construa a consulta Flux para selecionar dados de frequência cardíaca
4
5     Execute a consulta no InfluxDB
6     Inicialize uma lista para armazenar os dados de frequência cardíaca
7
8     Para cada resultado da consulta:
9         Transforme cada registro em um dicionário de valor e timestamp
10        Adicione à lista de dados de frequência cardíaca
11
12    Retorne a lista compilada de dicionários com dados de frequência cardíaca
13 Fim da Função
```

Cálculo da Pontuação de Frequência Cardíaca:

A função `calculate_heart_rate_score` desempenha um papel vital na avaliação da saúde cardíaca dos usuários do sistema *e-Health*, integrando dados de frequência cardíaca e atividade física para produzir uma pontuação quantitativa. Esta abordagem alinha-se com pesquisas que sublinham a importância de combinar informações de movimento e frequência cardíaca na avaliação abrangente da saúde cardíaca [176].

O cálculo começa com a definição de um intervalo normal para batimentos cardíacos por minuto (BPM) e verifica a atividade física do usuário, considerando os passos dados

nos últimos 30 minutos. Se a atividade física exceder um limiar predefinido, refletindo um estilo de vida ativo, a função atribui a pontuação máxima, reconhecendo a contribuição positiva da atividade física para a saúde cardíaca [177].

Para usuários inativos, a análise foca nas leituras de frequência cardíaca recentes. Leituras fora do intervalo normal de BPM são penalizadas, diminuindo a pontuação final de saúde cardíaca. Este método ressalta a relevância de monitorar a frequência cardíaca regularmente, possibilitando a identificação precoce de potenciais questões cardíacas [178]. Para ilustrar o processo de cálculo da pontuação de saúde cardíaca, segue abaixo um pseudocódigo que encapsula a lógica operacional da função.

```

1  Função para calcular a pontuação da Frequência Cardíaca.
2  Função calculate_heart_rate_score(dados_frequência_cardíaca, dados_passos):
3      Estabeleça o intervalo normal de BPM
4      Determine a atividade do usuário com base nos dados_passos recentes
5
6      Se atividade suficiente:
7          Atribua pontuação máxima
8
9      Caso contrário:
10         Avalie dados_frequência_cardíaca recentes
11         Se dados insuficientes:
12             Retorne indeterminado
13
14         Calcule penalidades por leituras anormais
15         Ajuste a pontuação de saúde cardíaca com base nas penalidades
16
17     Retorne pontuação
18 Fim da Função
```

4.3.4 Avaliação dos dados de *Feedback* de Tristeza

A função `get_sadness_feedback_data` é um componente crítico no sistema *e-Health*, focado na avaliação da saúde emocional do usuário por meio da coleta de *feedback* sobre tristeza. Esta abordagem permite uma compreensão detalhada do estado emocional do

usuário, baseada na sua própria percepção, o que é fundamental para o desenvolvimento de intervenções personalizadas eficazes [179].

Essencialmente, a função recupera o registro mais recente de *feedback* de tristeza, refletindo a autoavaliação do usuário sobre seus sentimentos. Isso assegura que as análises e intervenções subsequentes sejam baseadas em informações atuais e relevantes, permitindo uma resposta adaptativa às necessidades emocionais do usuário. A eficácia desta função em capturar os dados de *feedback* de tristeza é crucial para uma compreensão posterior aprofundada do estado emocional do usuário, possibilitando a implementação de estratégias de apoio personalizadas e orientadas por dados [180].

Na presença de dados de *feedback*, a função retorna o valor mais recente registrado. Na ausência de registros recentes, um valor padrão é fornecido, indicando a falta de *feedback* de tristeza, o que é primordial para garantir que o sistema possa manejar eficientemente a ausência de dados emocionais do usuário para análise. Segue o pseudocódigo para a função `get_sadness_feedback_data`, ilustrando a lógica operacional da função.

```

----- Consulta do Feedback do Usuário. -----
1  Função get_sadness_feedback_data(usuario):
2      Formule a consulta Flux para extrair o último registro de feedback de
3      tristeza para o usuário
4      Execute a consulta ao InfluxDB
5
6      Se houver registros disponíveis:
7          Retorne o valor do último feedback de tristeza
8      Caso contrário:
9          Retorne 0, indicando a ausência de feedback de tristeza
10
11     Retorne o resultado obtido ou o valor padrão
12 Fim da Função
```

Cálculo da Pontuação do *Feedback* de Tristeza

A função `calculate_sadness_feedback_score` é essencial no sistema *e-Health* para avaliar o estado emocional de tristeza do usuário com base no *feedback* fornecido. Utilizando

emojis que representam diferentes estados emocionais, conforme ilustrado na Figura 4.1, esta função atribui uma pontuação numérica que reflete o nível de tristeza expresso. O usuário seleciona o **emoji** que melhor representa seu estado de tristeza atual, influenciando diretamente a pontuação derivada.

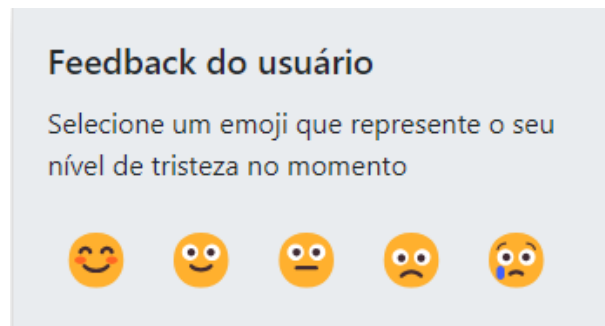


Figura 4.1: Interface de seleção de emoji para *feedback* do usuário.

Cada **emoji** está associado a uma pontuação específica, fornecendo uma maneira intuitiva e visual para o usuário comunicar seu humor. A escala de **emojis** e as pontuações correspondentes, ordenadas do mais positivo ao mais negativo, da esquerda para direita, são as seguintes:

- **Excelente:** Representa um estado de felicidade ou satisfação, associado a uma pontuação de 10.
- **Bom:** Indica um humor positivo, mas mais moderado, com uma pontuação de 8.
- **Médio:** Reflete um estado emocional neutro, atribuído a uma pontuação de 5.
- **Ruim:** Expressa um nível leve de tristeza, com uma pontuação de 3.
- **Muito Ruim:** Representa um estado de tristeza profunda ou desconforto, com a menor pontuação de 1.

Essas pontuações são normalizadas para uma escala de 0 a 100, alinhando-se com o padrão das outras métricas de saúde do sistema. Este método de *feedback* rápido e eficaz

é primordial para o monitoramento contínuo do bem-estar emocional do usuário e para a adaptação das recomendações de saúde fornecidas pelo sistema.

Inicialmente, a função `calculate_sadness_feedback_score` processa o *feedback* representado por `emojis` para avaliar o estado emocional de tristeza do usuário. Ela seleciona o registro mais recente de *feedback* e, a partir dessa informação, aplica uma escala inversa para calcular a pontuação de tristeza fornecida pelo usuário, onde valores mais elevados do *feedback* indicam menor tristeza e resultam em pontuações numéricas menores, e vice-versa. Esta abordagem assegura que a pontuação reflita adequadamente a intensidade da tristeza expressa pelo usuário, transformando a escala de *feedback* em uma pontuação compreensível de 0 a 100. Em situações onde o *feedback* é inexistente ou não é válido, a função é programada para retornar um valor nulo, indicando a ausência de dados suficientes para uma avaliação apropriada.

A pontuação resultante oferece uma medida quantitativa do bem-estar emocional do usuário, facilitando a identificação de mudanças no estado emocional ao longo do tempo. Este processo quantitativo é essencial para personalizar as intervenções de saúde de bem-estar, baseando-se em evidências para melhorar a eficácia do suporte oferecido [181] [182]. Abaixo, é possível observar o pseudocódigo ilustrando o método de cálculo discutido.

```

----- Função para calculo da pontuação de tristeza. -----
1  Função calculate_sadness_feedback_score(dados_feedback_tristeza):
2      Se os dados de feedback de tristeza forem uma lista e não estiverem vazios:
3          Extrai o valor mais recente de feedback da tristeza
4      Se os dados de feedback de tristeza forem um valor numérico:
5          Usa esse valor como o feedback de tristeza mais recente
6      Caso contrário:
7          Retorna None, indicando a ausência de dados válidos
8      Normaliza o valor de feedback de tristeza
9      Calcule a pontuação de feedback de tristeza numa escala de 0 a 100
10     Arredonde a pontuação para o inteiro mais próximo
11     Retorne a pontuação de feedback de tristeza
12 Fim da Função
```

4.3.5 Pontuação de Estresse

A pontuações de estresse, ansiedade e tristeza seguem a padronização do sistema que foi comentada na Seção 3.3, sendo 100 os melhores valores obtidos, representando boas pontuações.

A função `calculate_stress_score` é descrita como um método para determinar o nível de estresse do usuário, integrando três indicadores chave: frequência cardíaca, qualidade do sono e nível de atividade física. Em caso de ausência de dados para qualquer uma dessas métricas, a função os trata como zero para assegurar a continuidade do cálculo.

Cada métrica é ponderada de acordo com sua influência no estresse para usuário em questão, validada através de questionários sobre o que se considerava ter maior influência. A frequência cardíaca e sono recebem um peso de 20% cada, enquanto a atividade física tem um peso de 60%. O resultado é um valor que reflete o nível de estresse do usuário, arredondado para duas casas decimais e limitado a um máximo de 100 para se alinhar com a escala padronizada do sistema [183]–[185]. Abaixo é possível ver o pseudocódigo que exemplifica o funcionamento da função.

```

1          Cálculo da pontuação de estresse.
2  Função calculate_stress_score(heart_rate_score, sleep_score,
3  activity_score):
4      peso_frequenciaCardíaca = 0.2
5      peso_sono = 0.2
6      peso_atividade = 0.6
7      Se pontuação_frequencia_cardiaca estiver vazio
8          pontuação_frequencia_cardiaca = 0
9      Se pontuação_sono estiver vazio
10         pontuação_sono = 0
11     Se pontuação_atividade estiver vazio
12         pontuação_atividade = 0
13
14     Calcule o nível de estresse usando os pesos determinados para cada pontuação
15         nivel_estresse = peso_frequenciaCardíaca * pontuação_frequencia_cardiaca + peso_sono *
16         pontuação_sono + peso_atividade * pontuação_atividade
```

```
17     Arredonde o nível de estresse para duas casas decimais
18     Limite o nível de estresse a um máximo de 100
19
20     Retorne o nível de estresse
21 Fim da Função
```

4.3.6 Pontuação de Ansiedade

A função `calculate_anxiety_score` é uma métrica que reflete várias dimensões da saúde, ela incorpora e pondera as diversas métricas de saúde discutidas anteriormente, incluindo frequência cardíaca, qualidade do sono, atividade física e níveis de estresse, para calcular uma pontuação, de ansiedade que espelha o estado emocional do usuário voluntário. Cada aspecto contribui com uma porcentagem específica para a pontuação final de ansiedade, que varia de 0 a 100, alinhando-se com a escala adotada para o sistema em geral.

Os componentes e suas contribuições percentuais são os seguintes:

- **Pontuação da Frequência Cardíaca (30%)**: A pontuação da frequência cardíaca contribui com 30% da pontuação total de ansiedade. Variações na frequência cardíaca, especialmente taxas elevadas, podem indicar níveis aumentados de ansiedade [186].
- **Pontuação do Sono (20%)**: Esta métrica corresponde a 20% da pontuação total. O sono desregulado ou insuficiente é comumente associado a maiores níveis de ansiedade [187].
- **Pontuação da Atividade Física (10%)**: Contribui com 10% da pontuação. A atividade física tem uma relação inversa com a ansiedade, sendo uma atividade menor um potencial indicador de ansiedade elevada [188].
- **Pontuação do Stress Média (40%)**: Com a maior ponderação, 40% da pontuação de ansiedade é derivada do nível de estresse, refletindo diretamente o bem-estar emocional do usuário [189].

A função ajusta automaticamente os valores de entrada para zero na ausência de dados (None) para cada métrica, garantindo que a pontuação de ansiedade possa ser calculada de forma confiável, mesmo com dados incompletos. O pseudocódigo para ilustrar o cálculo da pontuação de ansiedade, consolidando a lógica operacional da função, pode ser visto a seguir.

```

----- Função para calculo da pontuação de Ansiedade. -----
1  Função calculate_anxiety_score(pontuação_frequencia_cardiaca, pontuação_sono,
2  pontuação_atividade, pontuação_stress):
3      Se qualquer pontuação de entrada for Nenhum, considera como zero
4
5      Calcula a pontuação de ansiedade aplicando os pesos específicos:
6          0.3 para a pontuação da frequência cardíaca
7          0.2 para a pontuação do sono
8          0.1 para a pontuação da atividade física
9          0.4 para a pontuação média de estresse
10
11     Retorna a pontuação de ansiedade calculada
12 Fim da Função
```

4.3.7 Pontuação de Tristeza

A função `calculate_sadness_score` é projetada para avaliar o estado de tristeza de um usuário, integrando e ponderando várias métricas de saúde relevantes. Semelhante ao método de cálculo da ansiedade, esta função considera aspectos como frequência cardíaca, qualidade do sono, atividade física, e inclui de maneira distinta o *feedback* direto do usuário sobre seu estado emocional. Cada componente tem uma ponderação específica para compor a escala de 0 a 100, refletindo sua contribuição para o estado geral de tristeza do usuário:

- **Pontuação da Frequência Cardíaca (30%):** Representando 30% da pontuação total, reflete como variações na frequência cardíaca podem estar associadas a estados emocionais como a tristeza [190].

- **Pontuação do Sono (20%)**: Contribuindo com 20%, a qualidade e duração do sono são fatores influentes no estado emocional e humor [191].
- **Pontuação da Atividade (10%)**: Atribui-se 10% ao nível de atividade física, considerando que a diminuição na atividade pode ser um indicador de um estado de humor deprimido [192].
- **Pontuação do *Feedback* de Tristeza (40%)**: O maior peso, 40%, é dado ao *feedback* direto do usuário sobre sua condição emocional, fornecendo uma medida subjetiva e valiosa do seu estado, devido a isso, o maior peso.

A função `calculate_sadness_score` também trata valores ausentes como zero para garantir a integridade do cálculo, refletindo uma pontuação de tristeza que sintetiza as informações de várias fontes para uma avaliação abrangente da tristeza do usuário. Especial ênfase é colocada no *feedback* do usuário, que fornece uma medida direta e pessoal do estado emocional. Segue abaixo o pseudocódigo que ilustra o processo de cálculo da pontuação de tristeza.

————— Função para cálculo da pontuação de Tristeza. —————

```
1  Função calculate_sadness_score(heart_rate_score, sleep_score, activity_score,
2  sadness_feedback_score):
3
4      Ajuste valores ausentes para zero para cada pontuação de entrada
5
6      Calcule a pontuação de tristeza aplicando os respectivos pesos:
7          0.3 para a pontuação da frequência cardíaca
8          0.2 para a pontuação do sono
9          0.1 para a pontuação da atividade física
10         0.4 para a pontuação do feedback de tristeza
11
12     Retorne a pontuação de tristeza calculada
13 Fim da Função
```

4.3.8 Armazenamento das pontuações

A função `get_and_save_scores` é responsável por compilar e armazenar pontuações de saúde no sistema *e-Health*, utilizando uma série de métricas para avaliar diferentes aspectos do bem-estar do usuário. A função extrai dados de várias fontes, incluindo informações sobre sono, atividade física, frequência cardíaca e feedback de tristeza, com base em uma data específica fornecida.

O processo começa utilizando as funções de cálculo de pontuações individuais para cada métrica de saúde: sono, atividade física, frequência cardíaca, estresse e feedback de tristeza. Após isso é obtida as pontuações de ansiedade e de tristeza, que integram as pontuações anteriores. As pontuações calculadas são então registradas no banco de dados *InfluxDB* com carimbos de data e hora atuais, assegurando que as informações estejam disponíveis para análises posteriores. Segue abaixo um pseudocódigo que descreve a função `calculate_and_save_scores`, exemplificando a operação da função.

```
----- Função para salvar as pontuações no banco de dados. -----  
1  Função get_and_save_scores(usuario, data)  
2      Colete dados de sono, passos, frequência cardíaca e  
3      feedback de tristeza  
4  
5      Obtenha as pontuações individuais para sono, atividade, frequência cardíaca e  
6      feedback de tristeza  
7  
8      Integre as pontuações individuais para calcular as  
9      pontuações de estresse, ansiedade e tristeza  
10  
11     Registre cada pontuação no InfluxDB com um carimbo de data/hora atual  
12  
13     Retorne confirmação de que as pontuações foram salvas  
14  Fim da Função
```

4.4 Modelo de Decisão

Após a avaliação e o cálculo das pontuações de saúde dos usuários, o sistema procede para a fase de decisão de recomendações. Este processo é essencial, pois é o ponto em que as métricas analíticas são transformadas em intervenções significativas e orientadas para a saúde do usuário. Este processo, que segue a lógica do fluxo de decisão ilustrado na imagem 3.8 na Seção 3.2.3, traduz análises quantitativas de saúde em orientações qualitativas personalizadas.

4.4.1 Modelo de Dados para Recomendações

O modelo `ScoreRecommendation` é composto por campos que definem as categorias de saúde (`score_type`) e delimitam os intervalos de pontuação (`min_score` e `max_score`), a fim de vincular pontuações específicas a recomendações apropriadas. O campo `recommendation_text` fornece o conteúdo da recomendação. Esta abordagem modular permite que os administradores atualizem as recomendações em resposta a novas evidências ou *feedback* dos usuários. Uma característica destacada pela capacidade de adaptação do sistema às inovações no campo da saúde digital [193]. É neste módulo onde são criadas as recomendações para os níveis de pontuações bons, médios e ruins. A seguir um pseudocódigo que ilustra a estruturação do modelo de recomendações é apresentado.

Função que cria o modelo das recomendações.

```
1 Classe ScoreRecommendation:
2     Inicialize score_type como uma string de até 100 caracteres
3     Inicialize min_score como um inteiro com valor padrão 0
4     Inicialize max_score como um inteiro com valor padrão 100
5     Inicialize recommendation_text como um campo de texto
6
7     Defina a representação da string do modelo para exibir o tipo de pontuação e
8     os intervalos de pontuação
```

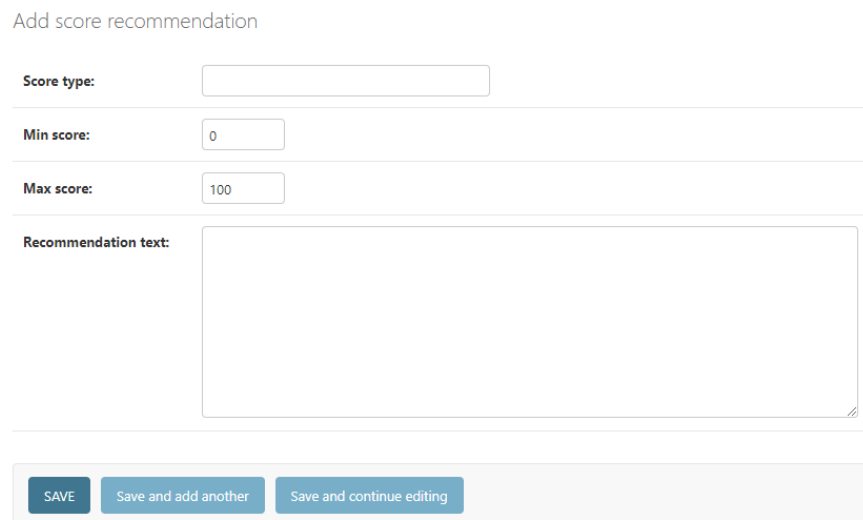
A configuração do *Django Admin* para o modelo `ScoreRecommendation` permite aos administradores do sistema visualizar e editar as recomendações de forma eficiente, o que

é fundamental para manter o sistema alinhado com as práticas atualizadas de saúde e as necessidades individuais dos usuários.

Configuração do Django Admin para o modelo ScoreRecommendatio.

```
1  Importe ScoreRecommendation
2
3  # Registro do modelo no Django Admin
4  Registre ScoreRecommendation no admin com a classe RecommendationAdmin
5      Defina RecommendationAdmin para personalizar a exibição no admin
6      Especifique 'score_type', 'min_score', 'max_score', 'recommendation_text' para
7      visualização
8
9  # Os administradores podem agora gerenciar as recomendações no Django Admin
```

A integração com o painel administrativo do *Django*, garante aos administradores do sistema a flexibilidade para decidir como adicionar, atualizar ou remover recomendações. Essa capacidade permite o refinamento contínuo e a adaptação do sistema às necessidades emergentes dos usuários, assegurando que recebam orientações pertinentes e personalizadas. Tal flexibilidade destaca a importância de modelos de dados eficientes para a criação de recomendações personalizadas [194]. A Figura 4.2 ilustra como é a interface de criação de recomendações no painel administrativo do *Django*.



Add score recommendation

Score type:

Min score:

Max score:

Recommendation text:

Figura 4.2: Recomendações obtidas do painel administrativo do *Django*.

Em resumo, o sistema *e-Health* não apenas avalia a condição de saúde do usuário através de métricas quantificáveis mas também atua ativamente para fornecer orientações que são práticas, compreensíveis e aplicáveis. A estrutura modular e a metodologia centrada no usuário garantem que as recomendações sejam não apenas cientificamente fundamentadas mas também personalizadas e relevantes para cada indivíduo, respeitando suas necessidades e preferências únicas.

4.5 Modelo de Ação no Ambiente

A ação no ambiente, discutida na Seção 3.2.4, é projetada através do desenvolvimento do *front-end* do sistema *e-Health*, que adota princípios de design centrado no usuário para criar uma interface intuitiva, funcional e esteticamente agradável. Utilizando tecnologias padrão da web, *HyperText Markup Language* (HTML), *JavaScript* e *BootStrap*, a interface foi projetada para ser responsiva, assegurando compatibilidade e acessibilidade em diferentes dispositivos e tamanhos de tela.

A estratégia de desenvolvimento enfatizou a modularização dos componentes da interface, permitindo uma manutenção e atualização eficientes, bem como a reutilização de código. Este documento detalhará a função e o código de cada arquivo HTML utilizado, juntamente com a lógica de *JavaScript* e *Django* aplicada para manipular eventos do usuário e a estilização *BootStrap* que define a estética visual do sistema.

4.5.1 Estrutura Base das Páginas

O arquivo `base.html` atua como o esqueleto estrutural no desenvolvimento do *front-end* do sistema. Como um template fundamental, ele estabelece a uniformidade visual e funcional em todas as páginas do site. Este arquivo define o cabeçalho (*header*) e rodapé (*footer*) padrão, incorpora as frameworks essenciais como *Bootstrap*, e estabelece o bloco de conteúdo principal (`% block content %`) para inserção de elementos específicos de cada página. Segue abaixo um pseudocódigo descrevendo a estrutura base dessa estrutura.

```
1 Documento HTML
2     Cabeçalho do HTML
3         Metadados
4         Links para CSS do Bootstrap
5     Corpo do documento
6         Cabeçalho da página
7             Elementos de navegação
8         Bloco de conteúdo principal
9             Conteúdo específico da página é inserido aqui
10        Rodapé da página
11            Informações do rodapé
12        Scripts JavaScript
13            Importação do jQuery e outros scripts necessários
```

4.5.2 Página Inicial

A página inicial do sistema *e-Health* desempenha o papel essencial de ponto de entrada para os usuários, apresentando o sistema e suas funcionalidades essenciais. Projetada para engajar os visitantes, a página inicial equilibra cuidadosamente a informação e a interatividade, fornecendo uma visão geral convidativa sem sobrecarregar os usuários.

O *layout* da página inclui um título destacado e um botão de ação que incentiva os visitantes a se inscreverem e começarem a explorar o sistema. Uma descrição sucinta esclarece a finalidade do sistema *e-Health* e seu potencial em auxiliar os usuários na gestão da saúde. Com uma interface de *design* limpo e atual, o layout visa promover uma experiência de usuário acessível e eficiente. Considera-se como sugestão para futuras melhorias, a possibilidade de aprimoramentos futuros no *design*, destacando a incorporação de mais elementos visuais para enriquecer a apresentação. A Figura 4.3 exibe um rascunho inicial desta página, contemplando essas considerações.

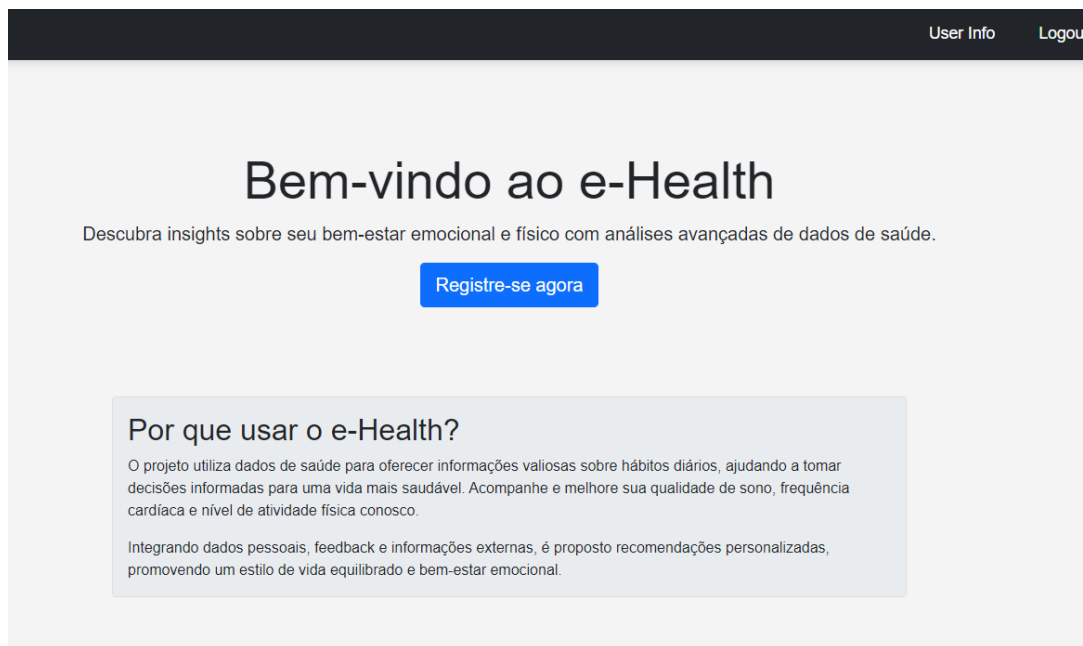


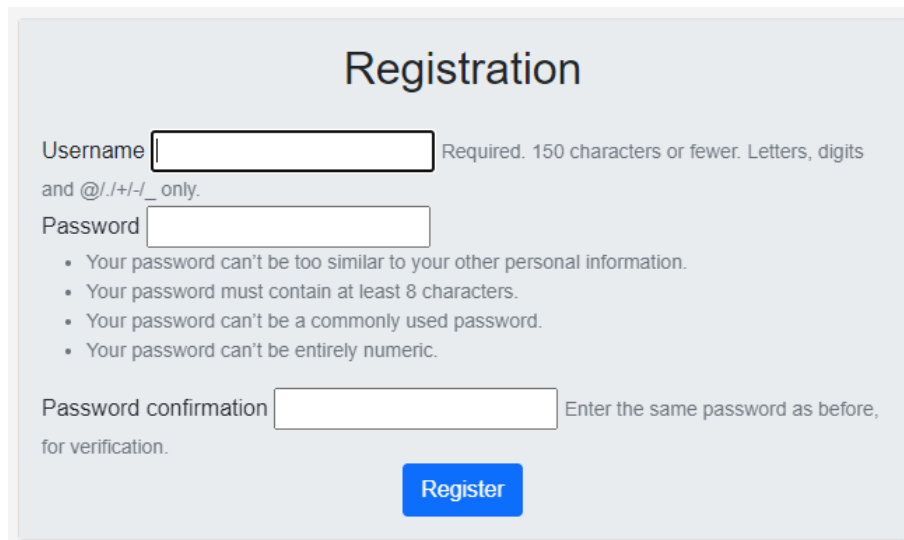
Figura 4.3: Página inicial do sistema *e-Health*.

4.5.3 Página de Registro

A interface de cadastro é fundamental para a admissão de novos usuários no sistema, sendo projetada para conciliar simplicidade operacional e medidas de segurança iniciais. Ela utiliza a linguagem de template do *Django* e está em consonância com as diretrizes de design do sistema, proporcionando uma experiência de usuário descomplicada e direta.

A proteção *Cross-Site Request Forgery (CSRF)* é incorporada para minimizar vulnerabilidades a ataques cibernéticos. Esta medida de segurança é importante para a proteção dos dados dos usuários durante o processo de cadastro.

Ao empregar o *framework* de formulários do *Django*, a interface procura oferecer consistência e eficiência na inscrição de novos participantes. Isso é feito adotando práticas recomendadas de segurança digital, assegurando que o processo de cadastro não só seja acessível, mas também seguro. A Figura 4.4 abaixo fornece uma representação visual da interface de registro.



The registration form is titled "Registration" and is contained within a light gray box. It features three input fields: "Username", "Password", and "Password confirmation". The "Username" field is followed by the text "Required. 150 characters or fewer. Letters, digits and @/./+/-/_ only." The "Password" field is followed by a bulleted list of requirements: "Your password can't be too similar to your other personal information.", "Your password must contain at least 8 characters.", "Your password can't be a commonly used password.", and "Your password can't be entirely numeric." The "Password confirmation" field is followed by the text "Enter the same password as before, for verification." A blue "Register" button is positioned at the bottom center of the form.

Figura 4.4: Área de registro do usuário.

4.5.4 Página de Login

A página de login é um ponto de entrada essencial para os usuários retornarem ao sistema. Foi projetada para ser consistente com o design geral do sistema, oferecendo uma experiência de usuário clara e objetiva. A interface de login é estruturada de forma a facilitar o processo de autenticação, com um layout que combina simplicidade e eficácia, é possível observar essa interface na Figura 4.5 abaixo.



The login form is titled "Login" and is contained within a light gray box. It features two input fields: "Username:" and "Password:". A blue "Login" button is positioned below the "Password:" field. At the bottom of the form, there is a link that says "No account? [Register](#)".

Figura 4.5: Área de *login* do usuário.

O sistema de *login* também utiliza o formulário padrão de login do *Django*, uma escolha

que reforça eficiência do processo de autenticação. O *Django*, sendo um *framework* robusto, oferece um formulário de login bem testado e seguro, garantindo que as credenciais dos usuários sejam manuseadas de maneira adequada.

Segurança no Login

A segurança é um pilar essencial no desenvolvimento de sistemas *e-Health*, com ênfase particular na autenticação de usuários. Para o sistema *e-Health*, a área de *login* foi desenvolvida priorizando a segurança, adotando os mecanismos padrões fornecidos pelo *Django*. Essas funcionalidades incluem autenticação de credenciais e gerenciamento de sessões seguras, estabelecendo uma fundação confiável para expandir o sistema para múltiplos usuários no futuro.

A utilização do *Django* para gerenciar o processo de *login* demonstra a implementação de práticas de segurança robustas, como a prevenção contra vulnerabilidades de *Cross-Site Request Forgery* (CSRF), assim como o registro, assegurando a proteção da integridade e confidencialidade dos dados dos usuários. Além disso, o *Django* suporta *hashing* de senhas, *tokens* de autenticação e gestão de permissões, elementos críticos para manter o acesso ao sistema restrito a usuários autorizados e garantir que as sessões sejam seguras contra ataques.

A seguir, um pseudocódigo ilustra a aplicação das funcionalidades de segurança do *Django* na área de *login*.

```

----- Autenticação e login -----
1  Importe as funções de autenticação e login do Django
2
3  Função para gerenciar o processo de login:
4      Autentique as credenciais do usuário
5      Se as credenciais forem válidas:
6          Inicie uma sessão segura
7      Caso contrário:
8          Retorne uma mensagem de erro
```

Este pseudocódigo reflete a abordagem adotada para garantir a segurança na área de

login, destacando a implementação de medidas de segurança escaláveis e eficazes. Mesmo em estágios iniciais, com um único usuário, tais práticas são essenciais e estabelecem uma base segura para a expansão do sistema. A segurança incorporada ao *framework Django* reforça a proteção contra ameaças comuns e assegura a confiabilidade do sistema *e-Health*[195]–[198].

Além do hashing de senhas, a cifragem (ou criptografia) de dados sensíveis armazenados no banco de dados poderia ser implementadas em fases futuras. Isso inclui informações pessoais dos usuários, registros de saúde e quaisquer outros dados que necessitem de proteção. Utilizar algoritmos de criptografia robustos, como AES (Advanced Encryption Standard), pode ajudar a proteger os dados contra acessos não autorizados, mesmo no caso de uma violação de dados [199], [200].

4.5.5 Página do Usuário

A página do usuário no sistema *e-Health* é projetada para engajar os indivíduos em um nível pessoal, oferecendo um espaço dedicado ao *feedback* emocional e ao acesso a dados de saúde contextualizados. Em vez de sobrecarregar os usuários com um fluxo constante de dados quantitativos, a interface prioriza a apresentação qualitativa das informações. Utiliza *emojis* para refletir estados emocionais e recomendações personalizadas para encorajar mudanças comportamentais positivas. Essa abordagem de design é intencionalmente escolhida para enriquecer a percepção do bem-estar dos usuários e facilitar uma interação mais intuitiva e menos técnica com o sistema [201], [202].

O sistema evita a apresentação direta de pontuações de saúde, direcionando a atenção do usuário para ações e *feedback* qualitativos. Esta abordagem minimiza o risco de fixação em números e enfatiza uma visão holística do autocuidado [203]. A interação com o sistema é facilitada por um *script JavaScript*, que não apenas processa a seleção intuitiva de *emojis* pelo usuário mas também garante uma comunicação fluida com o servidor através de pedidos *AJAX*, resultando em uma experiência de usuário dinâmica e sem interrupções.

Adicionalmente, a página oferece recomendações personalizadas baseadas nas pontuações de saúde do usuário, apresentadas em cartões distintos. Essas recomendações são alinhadas com a lógica de recomendação detalhada na Seção 4.4.1, adaptando as sugestões de forma precisa às métricas de saúde individuais do usuário. Essa personalização possibilita que cada usuário receba orientações que não apenas ressoam com suas condições de saúde únicas mas também incentivam a adoção de hábitos saudáveis sustentáveis. A Figura 4.6 ilustra essa interface de recomendações personalizadas.



Figura 4.6: Seção de recomendações personalizadas na página do usuário.

Abaixo também tem-se um pseudocódigo que reflete a funcionalidade da página do usuário.

```
Página do Usuário.
1 Seção de feedback emocional com emojis
2   Usuário seleciona emoji para registrar o estado emocional
3   Script JavaScript processa o clique e envia dados ao servidor via AJAX
4   Botões de emoji são desabilitados após a submissão para garantir a
5   integridade dos dados
6
7 Seção de recomendações personalizadas
8   Cartões de recomendação exibem sugestões baseadas nas pontuações de
```

```
9      saúde do usuário
10     Cada recomendação é categorizada e alinhada com as métricas de saúde
11     correspondentes
```

4.5.6 Processo de Escolha de Recomendações

A função `get_recommendations_for_scores` no sistema *e-Health* é um mecanismo destinado a fornecer recomendações personalizadas aos usuários com base em suas pontuações de saúde. O processo começa com a normalização das pontuações, arredondando-as para o número inteiro mais próximo, o que facilita a busca por recomendações correspondentes no banco de dados, utilizando o operador Q do *Django ORM* para filtrar as entradas no modelo de recomendação [204]–[206]. Esse arredondamento também foi feito como uma medida de prevenir erros com pontuações e cálculos, uma boa prática.

A função não se limita a encontrar uma correspondência exata entre a pontuação e as recomendações disponíveis; ela é projetada para selecionar aleatoriamente entre múltiplas recomendações aplicáveis, oferecendo uma variedade de conselhos e prevenindo a repetição que poderia levar ao desinteresse do usuário. Esta abordagem garante que o sistema forneça um *feedback* significativo e engajador, adaptado às necessidades individuais do usuário e às suas pontuações específicas.

Se não houver uma recomendação adequada disponível, ou se ocorrer um erro durante a busca, o sistema apresentará uma mensagem padrão, assegurando que o usuário receba orientação em todas as interações com a plataforma. Isso maximiza o impacto positivo das recomendações na saúde e bem-estar dos usuários, reforçando o compromisso do sistema com a entrega de um serviço atento e centrado no usuário [204]–[206]. Segue abaixo o pseudocódigo para ilustrar a função `get_recommendations_for_scores`.

```
_____ Função que busca recomendações. _____
1  Função get_recommendations_for_scores(pontuações_usuario)
2      Inicialize um dicionário vazio para as recomendações
3
4      Para cada tipo de pontuação e sua respectiva pontuação no dicionário de
5      pontuações do usuário:
```

```
6      Arredonde a pontuação para o inteiro mais próximo
7
8      Busque no banco de dados todas as recomendações aplicáveis
9      Se múltiplas recomendações forem encontradas:
10         Escolha uma recomendação aleatoriamente para diversificação
11         Adicione a recomendação escolhida ao dicionário de recomendações
12      Se nenhuma recomendação for encontrada:
13         Adicione uma mensagem padrão ao dicionário
14
15      Retorne o dicionário de recomendações
16 Fim da Função
```


Capítulo 5

Resultados e Discussão

Os resultados demonstraram que o dispositivo Garmin, integrado ao sistema e-Health, foi eficiente na recolha contínua de dados fisiológicos, incluindo atividade física, frequência cardíaca e qualidade do sono. Os resultados seguintes demonstram como o dispositivo foi capaz de recolher as informações para que estas fossem analisadas pelo sistema.

A análise dos dados recolhidos revelou que o sistema e-Health processou e interpretou adequadamente essas informações, gerando pontuações de saúde relevantes que demonstraram a situação de bem-estar atual do usuário e tiveram a veracidade confirmadas pelo mesmo. As pontuações calculadas de estresse, ansiedade e tristeza refletiram o estado de bem-estar do utilizador do sistema, informação que o teste possibilitou verificar.

Além disso, foi possível avaliar a eficácia das intervenções sugeridas pelo sistema *e-Health* através dos testes e das figuras gráficas que mostram as pontuações ao longo de um período. As Figuras que serão vistas nos testes a seguir, exemplificam como as recomendações personalizadas baseadas nos dados recolhidos influenciaram positivamente as métricas de saúde monitoradas. Em particular, notou-se uma melhora nos índices de bem-estar emocional do usuário após seguir as recomendações do sistema, validando a efetividade do sistema *e-Health* como uma ferramenta de suporte a saúde.

5.1 Análise dos Resultados

Serão analisados os resultados obtidos para cada métrica de saúde monitorada pelo sistema *e-Health*, enfatizando a correlação entre os dados recolhidos pelo dispositivo Garmin Vivoactive 3 e as pontuações calculadas pelo sistema.

5.1.1 Verificação de Dados no *InfluxDB*

O principal objetivo deste teste foi verificar a correta armazenagem de dados de saúde no *InfluxDB* e a precisão destes dados para monitoramento em tempo real, utilizando o Garmin Vivoactive 3. Métricas como qualidade do sono, frequência cardíaca, contagem de passos e *feedback* de tristeza foram verificadas através de questionamentos aos usuários para confirmar a precisão dos dados registrados no banco de dados, por exemplo se a quantidade de passos diárias eram confirmadas pelo usuário. Consultas manuais no *InfluxDB* garantiram o armazenamento dos dados, visando refletir o comportamento do usuário.

A Figura 5.1 ilustra os dados de frequência cardíaca registrados no *InfluxDB*, refletindo a funcionalidade de monitoramento do sistema *e-Health*. Nela, se exibe a frequência cardíaca capturada em batimentos por minuto (BPM) em um intervalo de 3 horas. Essa oscilação na frequência cardíaca é uma adaptação fisiológica normal, sendo um mecanismo para o ajuste do fluxo sanguíneo e suporte das demandas metabólicas do corpo [207], [208].




Figura 5.1: Dados de frequência cardíaca.

No eixo horizontal, se observa a progressão temporal, destacando o momento específico de cada leitura de BPM. O eixo vertical, por sua vez, indica a frequência cardíaca medida, onde a amplitude das variações sinaliza a resposta fisiológica do usuário a atividades e estados emocionais variados.

Este gráfico serve como uma confirmação visual de que os dados de saúde estão sendo coletados e armazenados, permitindo análises subsequentes e a validação da integridade dos dados no sistema. A apresentação visual dos dados no *InfluxDB* não inclui explicitamente as unidades de medida devido às características da plataforma, mas a representação gráfica cumpre seu papel ao assegurar que os registros de frequência cardíaca estão disponíveis, servindo como base para futuras consultas e análises detalhadas.

A seguir, é feita a confirmação dos dados da quantidade de passos, Figura 5.2 apresenta os dados de contagem de passos de um usuário, registrados e visualizados através do *InfluxDB*. Esta métrica de atividade física reflete os movimentos do usuário durante um intervalo de tempo específico. O gráfico traça a quantidade de passos dados, com o eixo horizontal indicando o tempo e o eixo vertical mostrando a contagem de passos. A representação gráfica facilita a identificação de períodos de maior atividade, inatividade ou repouso, onde a contagem é reduzida ou nula.

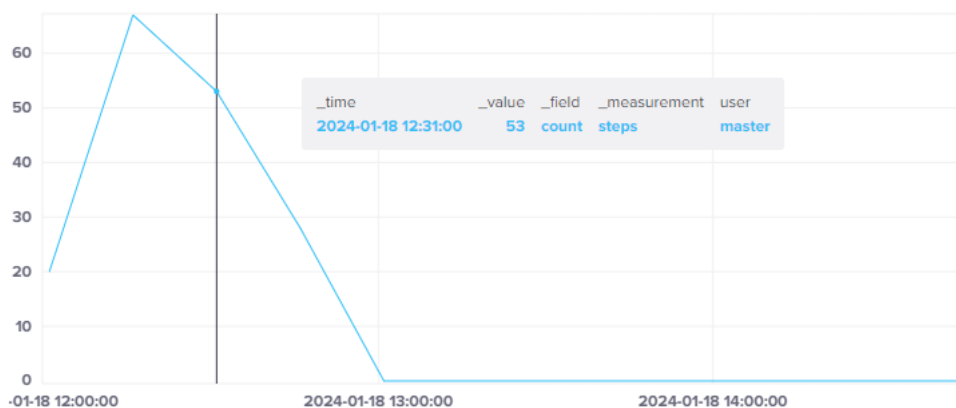


Figura 5.2: Dados de contagem de passos.

O gráfico seguinte, Figura 5.3, mostra uma linha para cada estágio do sono e os períodos de estar acordado, indicados pelo eixo vertical que representa a duração em minutos, confirmando a presença da informação no banco de dados. O eixo horizontal exibe o tempo

ao longo de uma noite, permitindo a visualização da progressão dos diferentes estágios do sono. As fases de sono leve, REM e profundo são essenciais para um descanso reparador, enquanto os períodos de vigília podem indicar interrupções no sono, que podem afetar sua qualidade global.




Figura 5.3: Dados de qualidade do sono da última noite.

A Figura 5.4 ilustra os dados de *feedback* de tristeza coletados pelo sistema. Observa-se que o eixo vertical indica a intensidade do sentimento de tristeza relatado pelo usuário através do sistema de feedback detalhado na Seção 4.3.4, numa escala inversa onde valores mais altos sugerem menor tristeza, enquanto valores mais baixos indicam maior tristeza. O eixo horizontal documenta os momentos exatos em que a métrica variou ao longo do tempo. Isso permite identificar padrões comportamentais e de bem-estar emocional, além de analisar a eficácia de intervenções de saúde, orientando ações personalizadas futuras.




Figura 5.4: Dados de *feedback* de tristeza.

5.1.2 Verificação do Sistema de Pontuações

O objetivo central deste teste é avaliar a exatidão com que o sistema *e-Health* processa os dados fisiológicos coletados e gera pontuações de saúde individualizadas. Especificamente, procura-se confirmar se o sistema calcula corretamente as pontuações baseadas em métricas como frequência cardíaca, atividade física (passos) e qualidade do sono, além de determinar as pontuações agregadas de tristeza, ansiedade e níveis de estresse.

O teste busca visualizar que essas pontuações sejam não apenas calculadas de acordo com os algoritmos predefinidos, vistos no Capítulo 4, mas também armazenadas de forma íntegra no banco de dados *InfluxDB*. A diferenciação entre dados de saúde coletados pelo Garmin e pontuações calculadas pelo sistema é fundamental, pois estas últimas buscam quantificar o bem-estar do usuário.

As análises no banco de dados confirmaram que dados de saúde, como frequência cardíaca, qualidade do sono, atividade e métricas de ansiedade, estresse e tristeza, são calculados e armazenados, indicando que o sistema processa e mantém a integridade dessas informações conforme planejado.

A Figura 5.5 mostra um gráfico de linha que representa a pontuação da frequência cardíaca (FC) ao longo do tempo. Esse gráfico indica a consistência na frequência cardíaca, refletindo uma saúde cardiovascular estável sem flutuações significativas que pudessem indicar episódios de estresse ou anormalidades cardíacas dentro do período demonstrado.

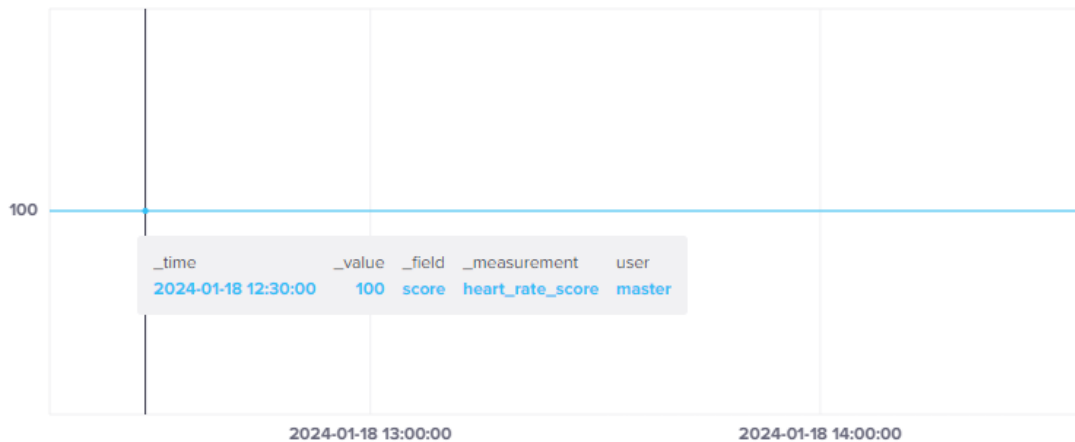


Figura 5.5: Pontuação da frequência cardíaca registrada no *InfluxDB*.

A próxima Figura 5.6 ilustra a autoavaliação do usuário sobre seu estado emocional, especificamente relacionado à tristeza, onde valores mais altos indicam uma percepção reduzida de tristeza, ou seja, momentos de contentamento ou bem-estar emocional. Esta pontuação, sendo um indicativo valioso do estado emocional autodeclarado do usuário, ganha importância quando correlacionada com outros dados comportamentais e fisiológicos recolhidos. Por exemplo, uma análise comparativa com dados de sono ou níveis de atividade pode revelar padrões e ajudar na compreensão do contexto por trás das variações emocionais relatadas [209].

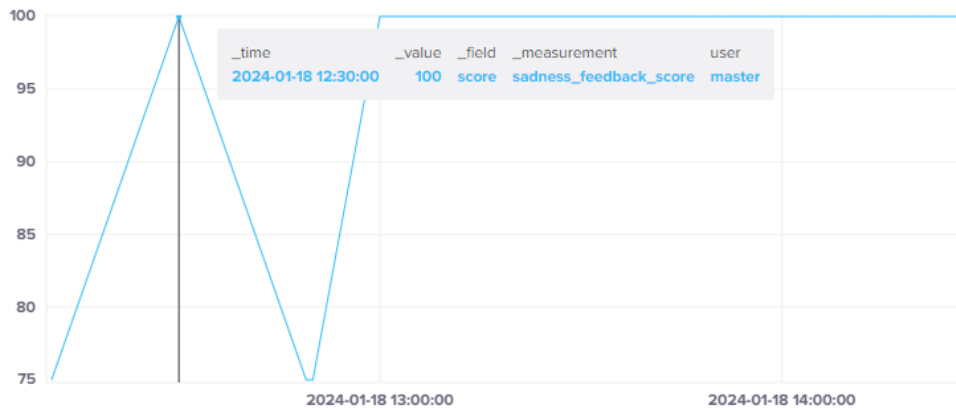


Figura 5.6: Pontuação do *feedback* de Tristeza registrada no *InfluxDB*.

A Figura 5.7 abaixo destaca as pontuações dos períodos de atividade física do usuário, com variações que correspondem a momentos de exercício ou movimento e valores que indicam repouso ou inatividade, revelando o padrão diário de atividades físicas.




Figura 5.7: Pontuação de atividade (passos) registrada no *InfluxDB*.

A Figura 5.8 exibe a pontuação de qualidade do sono do usuário, atingindo o máximo de 100, refletindo uma excelente qualidade de sono sem interrupções significativas, o que é vital para a recuperação [210].



Figura 5.8: Pontuação de qualidade do sono registrada no *InfluxDB*.

Os gráficos subsequentes representam as pontuações calculadas, derivadas das métricas anteriores, ilustrando a verificação bem-sucedida do salvamento dessas pontuações no banco de dados.

A linha do gráfico de estresse da Figura 5.9 a seguir varia ao longo do dia, demonstrando a resposta do usuário aos estressores cotidianos. A pontuação oscila entre momentos de maior relaxamento, indicados por pontuações mais elevadas, e períodos de possível estresse ou atividade, denotados pelas pontuações menores.




Figura 5.9: Pontuação de nível de estresse registrada no *InfluxDB*.

A Figura 5.10 seguinte ilustra como a pontuação que foi calculada para a ansiedade foi salva no banco de dados com êxito, permitindo o uso dela para futuras análises.




Figura 5.10: Pontuação de nível de ansiedade registrada no *InfluxDB*.

Por fim, finalizando a observação de que as todas as pontuações foram salvas com sucesso no banco de dados, a Figura 5.11 mostra a pontuação calculada para a tristeza salva no banco de dados.




Figura 5.11: Pontuação de nível de tristeza registrada no *InfluxDB*.

5.1.3 Impacto das Recomendações para Ansiedade e Tristeza

O objetivo principal desses testes foi avaliar o impacto das recomendações, seguidas pelo usuário, nas pontuações relativas às métricas de tristeza e ansiedade. Para tanto, foram escolhidos episódios em que as métricas do usuário demonstravam valores consistentemente similares ou próximos em diversas ocasiões.

Na metodologia empregada para a avaliação do impacto das recomendações nas métricas de tristeza e ansiedade, foi crucial a definição e seleção de episódios caracterizados por métricas fisiológicas consistentes. Para isso, estabeleceu-se um critério quantitativo para identificar 'similares ou muito próximas' características fisiológicas, baseando-se em variações mínimas pré-definidas para cada métrica específica.

Por exemplo, considerou-se que variações de 10 pontos de atividades físicas, frequência cardíaca e qualidade do sono eram 'muito próximas'. Este critério permitiu a seleção de episódios onde as respostas fisiológicas do usuário permaneciam dentro desses limites estreitos, fornecendo uma base para avaliar as recomendações do sistema. A aplicação deste método permitiu que a análise se concentrasse em dados representativos de estados fisiológicos semelhantes, facilitando uma avaliação do impacto das intervenções recomendadas.

Em um cenário específico, caracterizado por pontuações reduzidas de atividade física, o usuário submeteu-se a este cenário aproximadamente 15 vezes ao longo de três semanas. Em cada episódio, respostas foram coletadas através de questionários aplicados antes e após a implementação das ações sugeridas pelo sistema de recomendações, detalhadas na Seção 3.4. Durante a fase de testes, notou-se que as métricas de frequência cardíaca e qualidade do sono do usuário mantiveram-se em níveis considerados 'bons', indicando que ajustes nessas áreas específicas não eram necessários, apenas continuar seguindo as boas práticas para manter os níveis satisfatórios.

A Figura 5.12 apresentada abaixo incorpora uma legenda detalhada de cores, designando cada uma das métricas em estudo, e ilustra a variação observada nas pontuações

dessas métricas. Esta visualização gráfica permite verificar os impactos das recomendações sobre as métricas de tristeza em um período de tempo definido.

Descrição	Cor
Pontuação da frequência cardíaca	Laranja
Pontuação do feedback de tristeza	Azul
Pontuação de tristeza	Verde
Pontuação do sono	Amarelo
Pontuação da atividade	Preto




Figura 5.12: Relação entre as pontuações para a Tristeza.

Após adotar as recomendações, o usuário experimentou uma melhora nas pontuações de tristeza devido ao aumento de sua atividade física, o que também trouxe benefícios a pontuação de estresse. Entretanto, uma vez que a atividade se estabilizou, o indivíduo começou a expressar insatisfação com os níveis de tristeza, representadas pelo *feedback*, linha azul. Contudo, as pontuações melhoraram novamente com a retomada do aumento na atividade, linha preta. O usuário mencionou que, seguindo as orientações propostas pela interface, sentiu uma melhora no seu bem-estar em 85% das ocasiões.

É importante salientar que as pontuações para a tristeza, qualidade do sono e frequência cardíaca estavam em níveis muito satisfatórios na maior parte dos testes nesse cenário, com valores acima de 80, mostrando o bem-estar do usuário estava em níveis bons. As

ocasionais baixas nas pontuações de tristeza, que surgiram a partir do *feedback* do usuário, foram eficazmente resolvidas com ajustes oportunos na sua rotina de atividades.

O próximo teste foi para a métrica de ansiedade, conduzido de maneira similar ao anterior, focou nos eventos mais frequentes para o usuário, ocorrendo aproximadamente 20 vezes em 3 semanas. O usuário foi questionado antes e depois de aplicar as recomendações mencionadas na Seção 3.4. Nesta ocasião as pontuações de frequência cardíaca e qualidade do sono estavam bem altas, apenas a atividade estava com pontuações ruins. A Figura 5.13 abaixo é uma representação das ocorrências obtidas, onde foi avaliado como se comportou as pontuações de estresse e ansiedade e também conta com uma legenda de cores para as linhas da Figura.

Descrição	Cor
Pontuação da Ansiedade	Laranja
Pontuação da Frequência Cardíaca	Azul
Pontuação do Sono	Verde
Pontuação do Estresse	Amarelo
Pontuação da atividade	Preto




Figura 5.13: Relação entre as pontuações para a Ansiedade.

Nesse caso, o usuário apresentou sentir mudanças em seu nível de ansiedade, representado pela cor laranja, entretanto, o nível de assertividade obtido não foi o esperado. Em

aproximadamente 65% das vezes que em que as recomendações foram seguidas, notaram-se mudanças nos níveis de ansiedade reportados pelo usuário, não obtendo um alto nível de precisão neste caso, pois as pontuações no banco de dados mostraram melhorias, mas o *feedback* do usuário era contrário a essas melhorias. Estas informações foram validadas através de questionamentos e validações perguntadas ao usuário, em todas as ocorrências, mantendo o *feedback* do mesmo sempre como relevante para o sistema.

Na Figura 5.13 é possível visualizar como pontuação de estresse se comportou, essa métrica está presente no cálculo da ansiedade, visto na Seção 4.3.6, portanto é possível ver sua curva acompanhando as demais. Além disso, se observa também a influenciada pelas outras métricas em seu comportamento, mostrando como a lógica desenvolvida para calcular a pontuação de estresse funcionou conforme o esperado.

5.2 Discussão das Implicações

Os resultados obtidos neste estudo destacam a contribuição dos dispositivos vestíveis, exemplificados pelo Garmin Vivoactive 3, para a evolução das práticas de saúde e monitoramento de indivíduos. A integração desses dispositivos com sistemas de saúde eletrônicos, representados pelo *e-Health*, sugere uma abordagem eficaz para o cuidado personalizado, possibilitando o acompanhamento contínuo de indicadores de saúde e bem-estar emocional. Tal acompanhamento facilita intervenções sob medida, melhorando a gestão da saúde individual.

A pesquisa buscou validar a eficácia do sistema *e-Health* em processar e converter dados fisiológicos coletados pelo dispositivo Garmin em pontuações que refletem o estado de saúde do usuário. A verificação da integridade dos processos de cálculo e armazenamento propõe uma base para a confiabilidade do sistema como ferramenta de monitoramento de saúde. Os resultados mostram a utilidade dessas pontuações para fundamentar análises futuras e recomendações de saúde. Se percebeu também que os pesos das funções de pontuações criadas poderiam estar em variáveis, permitindo o ajuste dinâmico, facilitando melhorias no sistema.

Adicionalmente, os testes reforçam a relevância de sistemas de recomendação baseados em evidências científicas para auxiliar os usuários em seu percurso de saúde e bem-estar. A observação de melhorias significativas após a aplicação de recomendações confirma o valor do sistema *e-Health* como um recurso de suporte, ressaltando a importância do acompanhamento contínuo e da adaptação das intervenções. As recomendações propostas oferecem orientação para melhoria da saúde física e mental, visando a promoção de um estilo de vida mais saudável e equilibrado [211]–[213].

Contudo, o estudo reconhece a importância do *feedback* do usuário e identifica áreas para aprimoramento, especialmente na calibração das métricas e na inclusão de novos indicadores fisiológicos para aprimorar a precisão na avaliação do bem-estar dos usuários. Essas áreas de melhoria destacam a necessidade de evolução contínua do sistema, visando otimizar a eficácia das intervenções de saúde personalizadas.

A questão da utilização de um único participante nos testes constitui uma limitação metodológica significativa, comprometendo a generalização dos resultados. A diversidade de dados é um fator crítico para a validação de sistemas e, sem ela, os resultados obtidos podem não refletir adequadamente o comportamento do sistema em cenários mais variados. Portanto, para trabalhos futuros indica-se a utilização de uma amostra mais ampla para aumentar a qualidade dos testes e da replicabilidade e generalização dos dados coletados com os usuários.

5.3 Objetivos Excedidos e Não Cumpridos

A avaliação deste estudo, com base nos objetivos estabelecidos no Capítulo 1 e nos resultados discutidos no Capítulo 5, permite identificar os aspectos em que o sistema *e-Health* integrado ao dispositivo Garmin Vivoactive 3 superou as expectativas e aqueles em que não cumpriu totalmente as previsões iniciais.

5.3.1 Objetivos Excedidos

Primeiramente, foi atingido parcialmente (devido às limitações da API) o objetivo de monitorar indicadores de saúde continuamente, como frequência cardíaca, atividade física, qualidade do sono, e estados emocionais, incluindo estresse, ansiedade e tristeza. A integração efetiva do dispositivo Garmin com o sistema permitiu uma recolha de dados fisiológicos coerentes, essencial para as análises subsequentes do bem-estar do usuário. Isto demonstra a capacidade do sistema em capturar uma gama abrangente de dados fisiológicos relevantes para a avaliação do estado de saúde do indivíduo.

Adicionalmente, o uso do *InfluxDB* para armazenar, processar e assegurar a integridade dos dados recolhidos provou ser uma escolha acertada. O banco de dados demonstrou eficiência no gerenciamento de grandes volumes de dados, facilitando operações de consulta rápidas e eficientes, o que é crucial para a análise de saúde em tempo real.

O desenvolvimento e a implementação de algoritmos em *Python* para o cálculo de pontuações de saúde e bem-estar emocional representaram outro ponto importante alcançado pela investigação. Esses algoritmos permitiram a quantificação de estados emocionais, como ansiedade e tristeza, com base nos dados recolhidos e no *feedback* do usuário, facilitando a geração de recomendações personalizadas para a melhoria do bem-estar. O funcionamento correto do sistema *e-Health* foi avaliado através de testes de funcionalidade e análise de dados.

A investigação sobre como as recomendações do sistema influenciam a melhoria dos indicadores de saúde e bem-estar dos usuários foi significativa. Observou-se que as recomendações personalizadas baseadas nos dados recolhidos e nas características do usuário tiveram um impacto positivo nas métricas de saúde monitoradas. Isso mostrou a efetividade do sistema como uma ferramenta de suporte ao auto gerenciamento da saúde e destacou o potencial das intervenções baseadas em dados para promover mudanças positivas no comportamento e na saúde dos usuários.

A relação entre comportamentos de dados fisiológicos, como frequência cardíaca, atividade física e qualidade do sono, com os valores calculados para tristeza, ansiedade e

estresse foi examinada e testada. A análise destes dados em conjunto com as respostas coletadas através dos questionamentos ao usuário, confirmaram correlações significativas entre os fatores, destacando a relação complexa entre os parâmetros fisiológicos e o bem-estar emocional calculado. Isso reforça a importância de abordagens integradas que consideram tanto aspectos físicos quanto emocionais na promoção da saúde.

Em resumo, o estudo alcançou com sucesso a maioria de seus objetivos, demonstrando o potencial significativo do sistema *e-Health* em contribuir para o avanço da saúde digital, especialmente no monitoramento e na promoção do bem-estar emocional e físico de indivíduos. A integração eficaz de dispositivos vestíveis com análise avançada de dados representa um passo importante em direção à personalização e à melhoria da gestão da saúde.

5.3.2 Objetivos Não Cumpridos

Apesar de sucessos significativos, a investigação não conseguiu alcançar plenamente alguns dos objetivos específicos estabelecidos.

A utilização de um único participante para testar o sistema limitou a capacidade de generalizar os resultados obtidos. A diversidade de contextos individuais é crucial para a validação de um sistema de saúde digital, e a falta dessa diversidade restringiu a avaliação abrangente da eficácia do sistema *e-Health* em diferentes condições fisiológicas e contextos de bem-estar.

A recolha de dados não foi contínua devido ao uso intermitente do dispositivo pelo participante e também para evitar bloqueios de requisição da API do fabricante. Períodos sem o uso do relógio resultaram em lacunas nos dados recolhidos, o que impactou a integridade e continuidade das informações necessárias para análises e recomendações precisas. Essa limitação poderia ter sido contornada tentando se implementar uma lógica para recolher, através da API, apenas os dados que não haviam sido recolhidos anteriormente, para minimizar a recolha de grande volumes de dados a todo momento.

A avaliação do impacto das intervenções sugeridas sobre os indicadores de saúde e

bem-estar foi, portanto, prejudicada pela falta de dados consistentes. A ausência de dados contínuos impõe desafios significativos para a avaliação rigorosa do impacto das intervenções sugeridas sobre os indicadores de saúde e bem-estar [214].

5.4 Considerações Finais dos Resultados

Os resultados obtidos neste estudo, ao avaliar a eficácia do dispositivo Garmin Vivoactive 3 integrado a um sistema *e-Health* desenvolvido, apresentam contribuições significativas e percepções em relação à literatura existente sobre tecnologias de saúde vestíveis. Demonstram a habilidade destes dispositivos de fornecerem dados contínuos acerca de atividade física, frequência cardíaca e qualidade do sono. Estes achados estão em alinhamento com as evidências que destacam o potencial destas tecnologias no suporte ao auto-gerenciamento da saúde e na promoção do bem-estar [215], [216].

A aplicação de algoritmos específicos para análise dos dados recolhidos neste estudo é corroborada por pesquisas que enfatizam a importância da análise sofisticada de dados para transformar grandes volumes de informações em percepções acionáveis para usuários e profissionais de saúde. Este enfoque destaca o papel crítico dos avanços em ciência de dados na otimização da utilidade dos dados de saúde coletados por dispositivos vestíveis [217], [218].

Por fim, se contribui para o campo da saúde digital ao confirmar e expandir percepções do bem-estar do usuário, oferecendo novas perspectivas sobre a análise de dados de saúde e a aplicação de intervenções baseadas em tecnologia vestível. As futuras direções de pesquisa devem focar na superação das limitações identificadas e na exploração de novas tecnologias e metodologias para avançar na integração e aplicação de sistemas de saúde digital personalizados [219], [220].

Capítulo 6

Conclusões

Este capítulo destila as essências do trabalho realizado, oferecendo uma visão holística das contribuições e aprendizados adquiridos ao longo deste estudo acadêmico. Através deste estudo, se demonstrou como a integração de tecnologias vestíveis e técnicas de análise de dados pode enriquecer o campo da saúde digital.

O sistema *e-Health* proposto, com sua capacidade de recolher, processar e analisar dados de saúde, representa significativamente a monitorização do bem-estar emocional dos indivíduos. Através de um conjunto de testes, o sistema provou ser uma ferramenta capaz de implicar mudanças para o usuário e oferecer percepções relevantes e personalizados para a melhoria da saúde e bem-estar.

A aplicação prática do sistema demonstrou seu potencial para funcionar como um assistente de saúde digital pessoal, proporcionando recomendações, oportunas que podem levar a mudanças comportamentais positivas. A plataforma *e-Health* foi projetada para ser intuitiva e centrada no usuário, o que facilita a adoção e a adaptação às recomendações fornecidas, incentivando uma maior conscientização sobre saúde e bem-estar.

Além disso, os resultados dos testes realizados reforçaram a importância de uma abordagem baseada em dados para a saúde digital. Ao seguir as recomendações do sistema, os usuários experimentaram melhorias nos indicadores de saúde, o que valida o modelo de recomendação adotado e oferece uma prova de conceito para a aplicação de sistemas

similares de bem-estar. Esses resultados atendem em grande medida aos objetivos inicialmente estipulados para o estudo e estabelecem bases sólidas para futuras pesquisas e inovações tecnológicas no campo da saúde eletrônica *e-Health*.

6.1 Limitações e Desafios

O desenvolvimento do sistema *e-Health*, embora bem-sucedido em muitos aspectos, encontrou barreiras e desafios significativos. Uma limitação primária foi a restrição nos testes a um único participante, o que inibe a generalização dos resultados. A interação complexa entre os diversos parâmetros fisiológicos individuais e a tecnologia do sistema *e-Health* requer validação através de uma amostra mais ampla e diversificada para assegurar a eficácia e precisão universal do sistema. A pesquisa e o desenvolvimento contínuo em tecnologias de saúde digital devem priorizar a validação de algoritmos e intervenções em grupos demográficos variados para melhorar a precisão e a eficácia das soluções de saúde digital [221].

A frequência da coleta de dados foi impactada pela necessidade de limitar o uso da *API* do *Garmin Connect* para evitar bloqueios, reduzindo a continuidade dos dados coletados. Além disso, o uso intermitente do relógio pelo usuário gerou lacunas nos dados, comprometendo a completude das informações e a capacidade de conduzir uma análise rigorosa dos impactos das intervenções do sistema sobre a saúde e o bem-estar do usuário. Outro ponto relevante, foi que devido a grande quantidade de dados requisitados em determinados momentos, o funcionamento do programa e da interface apresentava uma certa demora para o carregamento, implicando em problemas para a experiência do usuário.

As limitações de tempo e recursos restringiram a exploração de técnicas avançadas de aprendizado de máquina e inteligência artificial, que poderiam oferecer dinamismo e personalização mais profunda nas recomendações do sistema *e-Health*. A natureza estática das recomendações atuais, embora eficazes, poderia ser substancialmente aprimorada para se adaptar às mudanças nas condições de saúde e preferências dos usuários em tempo real.

Por fim, a expansão da tecnologia para outros modelos de dispositivos vestíveis é um desafio decorrente da rápida evolução do mercado de vestíveis. A capacidade de adaptar o sistema *e-Health* para funcionar efetivamente com uma variedade de dispositivos é crucial para a sua aplicabilidade em uma escala mais ampla. A investigação forneceu percepções valiosas para a pesquisa futura, destacando a necessidade de desenvolvimento contínuo de tecnologias de saúde digital mais precisas, algoritmos robustos e ferramentas validadas para grupos demográficos amplos e diversificados.

Estas limitações e desafios refletem o estado atual da investigação e delineiam áreas para desenvolvimento futuro, assegurando que os esforços subsequentes sejam direcionados para superar esses obstáculos e expandir as capacidades do sistema *e-Health*. Cada uma dessas limitações é fundamental para entender as fronteiras atuais do estudo e guiar o caminho para avanços futuros na área de saúde digital e monitoramento de bem-estar por meio de tecnologias vestíveis.

6.2 Sugestões para Trabalhos Futuros

Este estudo estabeleceu um avanço significativo no uso de dispositivos vestíveis e análise comportamental para o monitoramento da saúde e bem-estar. No entanto, existe um amplo espaço para expansão e melhorias. Para futuras pesquisas, recomenda-se ampliar a diversificação da base de usuários visando uma representatividade mais ampla da população.

Além disso, a implementação de técnicas sofisticadas de inteligência artificial e algoritmos de aprendizado de máquina surge como um campo promissor para a customização do cuidado em saúde. A personalização das recomendações, ajustadas em tempo real por meio de análises longitudinais, é fundamental para satisfazer as necessidades individuais. A habilidade do sistema em aprender e se ajustar aos padrões de comportamento e saúde do usuário é essencial para prover intervenções mais precisas e efetivas.

Para além do alcance inicial desta investigação, futuras iterações deverão implementar práticas de segurança de dados mais robustas, assegurando a privacidade e proteção das

informações de saúde em uma base de usuários ampliada. A inclusão de uma variedade de modelos de diferentes fabricantes pode fornecer uma visão mais abrangente e comparativa da eficácia dos sistemas de saúde digital e das metodologias de recolha de dados. Esta abordagem multifacetada não apenas permitiria a validação cruzada dos resultados obtidos com o Garmin Vivoactive 3, mas também ofereceria percepções sobre a interoperabilidade e a adaptabilidade dos algoritmos de saúde digital em uma gama mais ampla de plataformas.

O desenvolvimento de um aplicativo móvel dedicado, com o intuito de oferecer aos usuários uma plataforma mais ágil, eficiente e de fácil acesso ao sistema *e-Health*. A mobilidade do aplicativo permitiria atualizações e notificações em tempo real, mantendo os usuários informados e engajados onde quer que estejam. As recomendações e dados recolhidos poderiam ser armazenados localmente no dispositivo, garantindo que o acompanhamento da saúde e bem-estar seja ininterrupto e personalizado. A integração do aplicativo com o estudo *e-Health* seria um passo significativo para ampliar a usabilidade e a adesão do sistema, tornando a gestão da saúde pessoal mais integrada ao cotidiano dos usuários. Nesse aplicativo móvel, o usuário poderia se autenticar no sistema com o mesmo usuário do seu dispositivo vestível, facilitando a interação com o fabricante do hardware.

A expansão do acesso das métricas personalizadas para profissionais da saúde potencializaria o uso do sistema, permitindo uma abordagem colaborativa e integrada no monitoramento e na intervenção. A criação de um *dashboard* interativo proporcionaria aos usuários e profissionais de saúde um monitoramento contínuo e detalhado dos dados de saúde, enriquecendo a experiência do usuário e ampliando o impacto do sistema no cotidiano.

A interação do sistema com a domótica abriria caminhos para uma abordagem holística do bem-estar, integrando métricas ambientais ao monitoramento de saúde e promovendo um sistema verdadeiramente alinhado ao ambiente de vida do usuário.

A criação de um assistente virtual interativo, funcionando como um "amigo" digital que acompanha o usuário ao longo do dia. Inspirado na nostálgica experiência dos *Tamagotchis*, amigo virtual, este assistente equipado com inteligência artificial sugeriria, de

maneira proativa e simpática, ações para melhorar o bem-estar do usuário. Essa presença virtual constante não só proporcionaria lembretes oportunos para práticas de saúde recomendadas, mas também ofereceria apoio emocional e motivação, contribuindo para um ambiente de cuidado contínuo e personalizado. A interação regular com o assistente tem o potencial de reforçar hábitos saudáveis e de estreitar a relação do usuário com o ecossistema *e-Health*, tornando o processo de cuidado à saúde uma experiência mais envolvente e amistosa.

A incorporação de elementos de gamificação no sistema de recomendações não só pode estimular a adesão do usuário às práticas de saúde sugeridas, mas também promove a adoção de comportamentos saudáveis de uma forma envolvente e motivadora. Ao oferecer recompensas por alcançar metas específicas, esse enfoque lúdico contribui para transformar a gestão da saúde em uma experiência mais gratificante e interativa, encorajando os usuários a se comprometerem ativamente com seus objetivos de saúde e bem-estar de maneira consistente.

Essas recomendações para trabalhos futuros buscam não só a continuidade do desenvolvimento tecnológico mas também a promoção de um sistema de saúde digital que seja interativo, adaptativo e respeitoso da diversidade e complexidade humanas. Estas diretrizes prospectivas são apresentadas com a expectativa de fomentar a pesquisa contínua e a inovação no campo da saúde digital, com o objetivo final de melhorar a qualidade de vida e bem-estar em escala global.

6.3 Considerações Finais

As conclusões desta investigação destacam a relevância e o potencial transformador da tecnologia digital aplicada à saúde. A implementação bem-sucedida do sistema *e-Health*, evidenciada pelos testes realizados, não apenas atesta a viabilidade de monitoramento e análise de bem-estar emocional através de tecnologias vestíveis, mas também contribui significativamente para o campo da saúde digital.

Este trabalho demonstrou a capacidade de coletar dados de saúde corretamente,

processá-los eficientemente e fornecer recomendações personalizadas e centradas no usuário, estabelecendo as bases para futuras pesquisas e avanços tecnológicos na área.

As soluções adotadas e os resultados alcançados no decorrer deste estudo fornecem uma base sólida para o desenvolvimento contínuo de soluções inovadoras que podem melhorar a qualidade de vida de indivíduos globalmente. A confiabilidade dos dados armazenados no *InfluxDB*, confirmada pelos testes, estabelece uma fundação de confiança no sistema *e-Health* e promove uma abordagem informada e baseada em dados para a gestão da saúde e do bem-estar.

Esta investigação ressalta a necessidade de sistemas de saúde digital que sejam não apenas eficazes e adaptáveis às necessidades atuais, mas que também possuam a flexibilidade para evoluir e responder às mudanças futuras. As contribuições deste trabalho enfatizam a importância do dinamismo e da resiliência como qualidades cruciais para a inovação na saúde digital, inspirando o contínuo desenvolvimento e pesquisa neste campo transformador.

Bibliografia

- [1] X. Wang, Z. Liu e T. Zhang, «Flexible Sensing Electronics for Wearable/Attachable Health Monitoring.», *Small*, vol. 13 25, 2017. DOI: 10.1002/sm11.201602790.
- [2] D. Dias e J. P. Cunha, «Wearable Health Devices—Vital Sign Monitoring, Systems and Technologies», *Sensors (Basel, Switzerland)*, vol. 18, 2018. DOI: 10.3390/s18082414.
- [3] D. Shapiro, L. Jamner e I. Goldstein, «Daily mood states and ambulatory blood pressure», *Psychophysiology*, vol. 34, n.º 4, pp. 399–405, 1997. DOI: 10.1111/J.1469-8986.1997.TB02383.X.
- [4] K. R. Fox, «The influence of physical activity on mental well-being», *Public Health Nutrition*, vol. 2, pp. 411–418, 1999. DOI: 10.1017/S1368980099000567.
- [5] R. Barroso, A. C. Silva-Filho, C. M. Dias, N. Soares, A. Mostarda, L. Azoubel, L. Melo, A. M. C. Garcia, B. Rodrigues e C. Mostarda, «Effect of exercise training in heart rate variability, anxiety, depression, and sleep quality in kidney recipients: A preliminary study», *Journal of Health Psychology*, vol. 24, pp. 299–308, 2019. DOI: 10.1177/1359105316676329.
- [6] E. Dejonckheere, B. Bastian, E. Fried, S. C. Murphy e P. Kuppens, «Perceiving social pressure not to feel negative predicts depressive symptoms in daily life», *Depression and Anxiety*, vol. 34, pp. 836–844, 2017. DOI: 10.1002/da.22653.
- [7] J. S. Yarrington, J. Lasser, D. Garcia, J. H. Vargas, D. D. Couto, T. Marafon, M. Craske e A. Niles, «Impact of the COVID-19 Pandemic on Mental Health among

- 157,213 Americans», *Journal of Affective Disorders*, vol. 286, pp. 64–70, 2021. DOI: 10.1016/j.jad.2021.02.056.
- [8] B. Bastian, P. Koval, Y. Erbas, M. Houben, M. Pe e P. Kuppens, «Sad and Alone», *Social Psychological and Personality Science*, vol. 6, pp. 496–503, 2015. DOI: 10.1177/1948550614568682.
- [9] G. P. Trotman, J. V. van Zanten, J. Davies, C. Möller, A. T. Ginty e S. E. Williams, «Associations between heart rate, perceived heart rate, and anxiety during acute psychological stress», *Anxiety, Stress, Coping*, vol. 32, pp. 711–727, 2019. DOI: 10.1080/10615806.2019.1648794.
- [10] H.-P. Lee, Y.-C. Liu e M.-F. Lin, «Effects of Different Genres of Music on the Psycho-Physiological Responses of Undergraduates.», *Hu li za zhi The journal of nursing*, vol. 63 6, pp. 77–88, 2016. DOI: 10.6224/JN.63.6.77.
- [11] M. Karki e G. Mahara, «Heart diseases, anxiety disorders, and negative thoughts», *Heart and Mind*, vol. 6, pp. 22–25, 2022. DOI: 10.4103/hm.hm_45_21.
- [12] R. White, M. J. Babic, P. Parker, D. Lubans, T. Astell-Burt e C. Lonsdale, «Domain-Specific Physical Activity and Mental Health: A Meta-analysis.», *American journal of preventive medicine*, vol. 52 5, pp. 653–666, 2017. DOI: 10.1016/j.amepre.2016.12.008.
- [13] D. Dinges, F. Pack, K. Williams, K. Gillen, J. Powell, G. Ott, C. Aptowicz e A. Pack, «Cumulative sleepiness, mood disturbance, and psychomotor vigilance performance decrements during a week of sleep restricted to 4-5 hours per night», *Sleep*, vol. 20, n.º 4, 1997.
- [14] D. Neckelmann, A. Mykletun e A. Dahl, «Chronic insomnia as a risk factor for developing anxiety and depression.», *Sleep*, vol. 30 7, pp. 873–80, 2007. DOI: 10.1093/SLEEP/30.7.873.

- [15] M. Ghamari, B. Janko, R. Sherratt, W. Harwin, R. Piechocki e C. Soltanpur, «A Survey on Wireless Body Area Networks for eHealthcare Systems in Residential Environments», *Sensors (Basel, Switzerland)*, vol. 16, 2016. DOI: 10.3390/s16060831.
- [16] B. W. An, J. H. Shin, S.-Y. Kim, J. Kim, S. Ji, J. Park, Y. Lee, J. Jang, Y.-G. Park, E. Cho, S. Jo e J. Park, «Smart Sensor Systems for Wearable Electronic Devices», *Polymers*, vol. 9, 2017. DOI: 10.3390/polym9080303.
- [17] H.Rao, «Trends in Health Wearables», *The International Journal of Frontier Sciences*, 2018. DOI: 10.37978/tijfs.v2i2.41.
- [18] H. Lewy, «Wearable devices - from healthy lifestyle to active ageing», em *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2015. DOI: 10.1109/EMBC.2015.7320188.
- [19] C. Xu, N. Wang, L. Zhu, K. Sharif e C. Zhang, «Achieving Searchable and Privacy-Preserving Data Sharing for Cloud-Assisted E-Healthcare System», *IEEE Internet of Things Journal*, vol. 6, pp. 8345–8356, 2019. DOI: 10.1109/JIOT.2019.2917186.
- [20] H. Lin, Q. He, J. Hu e X. Wang, «Blockchain-Based Data Access Security Solutions for Medical Wearables», *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, 2023.
- [21] H. Rafik, A. Maizate e A. Ettaoufik, «Data Security Mechanisms, Approaches, and Challenges for e-Health Smart Systems», *International Journal of Online Engineering (iJOE)*, 2023.
- [22] E. Topol, «High-performance medicine: the convergence of human and artificial intelligence», *Nature Medicine*, vol. 25, pp. 44–56, 2019. DOI: 10.1038/s41591-018-0300-7.
- [23] S. Canali, V. Schiaffonati e A. Aliverti, «Challenges and recommendations for wearable devices in digital health: Data quality, interoperability, health equity, fairness», *PLOS Digital Health*, 2022.

- [24] M. A. A. Saleh et al., «Health Wearable IoT (WIoT) Technology Devices Security and Privacy Vulnerability Analysis», *Proceedings of the Information Technology Trends*, 2022.
- [25] A. Koren e R. Prasad, «IoT Health Data in Electronic Health Records (EHR): Security and Privacy Issues in Era of 6G», *J. ICT Stand.*, vol. 10, 2022. DOI: 10.13052/jicts2245-800x.1014.
- [26] C. Fernández-Rovira et al., «The digital transformation of business. Towards the datafication of the relationship with customers», *Technological Forecasting and Social Change*, vol. 162, p. 120 339, 2021. DOI: 10.1016/J.TECHFORE.2020.120339.
- [27] M. Haghi, K. Thurow e R. Stoll, «Wearable Devices in Medical Internet of Things: Scientific Research and Commercially Available Devices», *Healthcare Informatics Research*, vol. 23, pp. 4–15, 2017. DOI: 10.4258/hir.2017.23.1.4.
- [28] K. Guk, G. Han, J. Lim, K. Jeong, T. Kang, E.-K. Lim e J. Jung, «Evolution of Wearable Devices with Real-Time Disease Monitoring for Personalized Healthcare», *Nanomaterials*, vol. 9, 2019. DOI: 10.3390/nano9060813.
- [29] C. Cheung, A. Krahn e J. Andrade, «The Emerging Role of Wearable Technologies in Detection of Arrhythmia», *The Canadian journal of cardiology*, vol. 34 8, pp. 1083–1087, 2018. DOI: 10.1016/j.cjca.2018.05.003.
- [30] M. Banasr, J. Dwyer e R. Duman, «Cell atrophy and loss in depression: reversal by antidepressant treatment.», *Current opinion in cell biology*, vol. 23 6, pp. 730–7, 2011. DOI: 10.1016/j.ceb.2011.09.002.
- [31] B. McEwen, N. Bowles, J. Gray, M. Hill, R. Hunter, I. Karatsoreos e C. Nasca, «Mechanisms of stress in the brain», *Nature Neuroscience*, vol. 18, pp. 1353–1363, 2015. DOI: 10.1038/nn.4086.
- [32] J. Xiong, O. Lipsitz, F. Nasri, L. Lui, H. Gill, L. Phan, D. Chen-Li, M. Iacobucci, R. Ho, A. Majeed e R. McIntyre, «Impact of COVID-19 pandemic on mental health

- in the general population: A systematic review», *Journal of Affective Disorders*, vol. 277, pp. 55–64, 2020. DOI: 10.1016/j.jad.2020.08.001.
- [33] X. Wang, S. Hegde, C. Son, B. Keller, A. Smith e F. Sasangohar, «Investigating Mental Health of US College Students During the COVID-19 Pandemic: Cross-Sectional Survey Study», *Journal of Medical Internet Research*, vol. 22, 2020. DOI: 10.2196/22817.
- [34] P. Goldin e J. Gross, «Effects of mindfulness-based stress reduction (MBSR) on emotion regulation in social anxiety disorder.», *Emotion*, vol. 10 1, pp. 83–91, 2010. DOI: 10.1037/a0018441.
- [35] H. Jazaieri, P. Goldin, K. Werner, M. Ziv e J. Gross, «A randomized trial of MBSR versus aerobic exercise for social anxiety disorder.», *Journal of clinical psychology*, vol. 68 7, pp. 715–31, 2012. DOI: 10.1002/jc1p.21863.
- [36] K.-q. Fan, Y.-y. Li, H.-l. Wang, X.-t. Mao, J.-x. Guo, F. Wang, L.-j. Huang, Y.-n. Li, X.-y. Ma, Z.-j. Gao, W. Chen, D. Qian, W. Xue, Q. Cao, L. Zhang, L. Shen, L. Zhang, C. Tong, J.-y. Zhong, W. Lu, L. Lu, K. Ren, G. Zhong, Y. Wang, M. Tang, X.-h. Feng, R. Chai e J. Jin, «Stress-Induced Metabolic Disorder in Peripheral CD4+ T Cells Leads to Anxiety-like Behavior», *Cell*, vol. 179, 864–879.e19, 2019. DOI: 10.1016/j.cell.2019.10.001.
- [37] A. G. Bottaccioli, F. Bottaccioli e A. Minelli, «Stress and the psyche–brain–immune network in psychiatric diseases based on psychoneuroendocrineimmunology: a concise review», *Annals of the New York Academy of Sciences*, vol. 1437, 2019. DOI: 10.1111/nyas.13728.
- [38] S. Neethirajan e B. Kemp, «Digital Twins in Livestock Farming», *Animals : an Open Access Journal from MDPI*, vol. 11, 2021. DOI: 10.3390/ani11041008.
- [39] L. Chin e S. Khozin, «A digital highway for data fluidity and data equity in precision medicine», *Biochimica et Biophysica Acta (BBA) - Reviews on Cancer*, vol. 188575, 2021. DOI: 10.1016/j.bbcan.2021.188575.

- [40] A. E. Saddik, «Digital Twins: The Convergence of Multimedia Technologies», *IEEE MultiMedia*, vol. 25, pp. 87–92, 2018. DOI: 10.1109/mmul.2018.023121167.
- [41] B. R. Barricelli, E. Casiraghi, J. Gliozzo, A. Petrini e S. Valtolina, «Human Digital Twin for Fitness Management», *IEEE Access*, vol. 8, pp. 26 637–26 664, 2020. DOI: 10.1109/ACCESS.2020.2971576.
- [42] A. Albraikan, «inHarmony: a Digital Twin for Emotional Well-being», 2019. DOI: 10.20381/RUOR-23480.
- [43] Y. Liu, L. Zhang, Y. Yang, L. Zhou, L. Ren, F. Wang, R. Liu, Z. Pang e M. Deen, «A Novel Cloud-Based Framework for the Elderly Healthcare Services Using Digital Twin», *IEEE Access*, vol. 7, pp. 49 088–49 101, 2019. DOI: 10.1109/ACCESS.2019.2909828.
- [44] G. Goncharova, «New digital opportunities in diagnosis and prevention of students' mental health», vol. 2021, n.º 030, 2022. DOI: 10.24075/rbh.2021.030.
- [45] M. Chen et al., «Guest Editorial Sensing Psychological Parameters and AI-Enabled Emotion Care for Human Wellness», *IEEE Journal of Biomedical and Health Informatics*, vol. 26, pp. 3594–3596, 2022. DOI: 10.1109/jbhi.2022.3190021.
- [46] M. Smits et al., «From Digital Health to Digital Well-being: Systematic Scoping Review», *Journal of Medical Internet Research*, vol. 24, 2022. DOI: 10.2196/33787.
- [47] M. Zaharov, R. Kirichek e A. Koucheryavy, «Overview of current research in Mobile Health», 2020. DOI: 10.31854/2307-1303-2020-8-3-63-70.
- [48] S. Munirman, E. Palantei, M. Baharuddin e Z. Rizal, «An IoT Wearable Communication Prototype Tested in Indoor and Outdoor Environments», 2020. DOI: 10.1109/Comnetsat50391.2020.9329007.
- [49] I. Buchem, R. Klamma e F. Wild, «Introduction to Wearable Enhanced Learning (WELL): Trends, Opportunities, and Challenges», 2019. DOI: 10.1007/978-3-319-64301-4_1.

- [50] Z. Bao e X. Chen, «Flexible and Stretchable Devices», 2016. DOI: 10.1002/adma.201601422.
- [51] A. Komolafe, B. Zaghari, R. Torah, A. Weddell, H. Khanbareh, Z. Tsikriteas, M. L. Vousden, M. Wagih, U. T. Jurado, J. Shi, S. Yong, S. Arumugam, Y. Li, K. Yang, G. Savelli, N. White e S. Beeby, «E-Textile Technology Review–From Materials to Application», 2021. DOI: 10.1109/ACCESS.2021.3094303.
- [52] L. Lu, J. Zhang, Y. Xie, F. Gao, S. Xu, X. Wu e Z. Ye, «Wearable Health Devices in Health Care: Narrative Systematic Review», 2020. DOI: 10.2196/18907.
- [53] M. Dastani e A. Atarodi, «Health Information Technology During the COVID-19 Epidemic: A Review via Text Mining», *Online Journal of Public Health Informatics*, 2022. DOI: 10.5210/ojphi.v14i1.11090.
- [54] B. S. Rakhimov, F. B. Rakhimova e S. K. Sobirova, «Modeling Database Management Systems in Medicine», *Journal of Physics: Conference Series*, 2021. DOI: 10.1088/1742-6596/1889/2/022028.
- [55] E. Long, B. Huang, L.-p. Wang, X. Lin e H. Lin, «Construction of Databases: Advances and Significance in Clinical Research», *Eye Science*, 2016. DOI: 10.21037/JES.2016.04.13.
- [56] M. Masud, M. S. Hossain, A. Alamri, A. S. Almogren e M. Zakariah, «Synchronizing Data through Update Queries in Interoperable E-Health and Technology Enhanced Learning Data Sharing Systems», *J. Univers. Comput. Sci.*, vol. 21, pp. 1439–1453, 2015.
- [57] W. Jin e D. Kim, «Design and Implementation of e-Health System Based on Semantic Sensor Network Using IETF YANG», *Sensors (Basel, Switzerland)*, vol. 18, 2018. DOI: 10.3390/s18020629.
- [58] K. Ndlovu, R. Scott e M. Mars, «Critical Analysis of e-Health Interoperability Frameworks – A Review of Reviews (Preprint)», 2018. DOI: 10.2196/preprints.12874.

- [59] A. Kouroubali e D. G. Katehakis, «The new European interoperability framework as a facilitator of digital transformation for citizen empowerment», *Journal of biomedical informatics*, vol. 94, p. 103166, 2019. DOI: 10.1016/j.jbi.2019.103166.
- [60] S. Alwi, M. A. Murad, S. Abdullah e A. Kamaruddin, «A Prototype Development and Usability Evaluation of an E-health System», *2022 Applied Informatics International Conference (AiIC)*, pp. 34–39, 2022. DOI: 10.1109/AiIC54368.2022.9914606.
- [61] D. Haniff, «Usability Engineering and E-Health», pp. 41–64, 2011. DOI: 10.4018/978-1-60960-177-5.CH003.
- [62] M. A. Hebert e E. Madigan, «Usability Study of a Simulated Electronic Health Record», *CIN: Computers, Informatics, Nursing*, vol. 36, pp. 569–575, 2018. DOI: 10.1097/CIN.0000000000000502.
- [63] H. Alzahrani e R. A. Alnanih, «A Design Study to Improve user Experience of a Procedure Booking Software in Healthcare», 2020. DOI: 10.14569/ijacsa.2020.0111132.
- [64] L. Morrison, C. Hargood, V. Pejović, A. W. A. Geraghty, S. Lloyd, N. Goodman, D. Michaelides, A. Weston, M. Musolesi, M. Weal e L. Yardley, «The Effect of Timing and Frequency of Push Notifications on Usage of a Smartphone-Based Stress Management Intervention: An Exploratory Trial», *PLoS ONE*, vol. 12, 2017. DOI: 10.1371/journal.pone.0169162.
- [65] A. Kushniruk e E. Borycki, «Usability of Healthcare Information Technology: Barrier to the Exchange of Health Information in the Two-Sided E-Health Market?», 2017. DOI: 10.1016/B978-0-12-805250-1.00007-1.
- [66] S.-R. Oh, Y.-D. Seo, E. Lee e Y.-G. Kim, «A Comprehensive Survey on Security and Privacy for Electronic Health Data», *International Journal of Environmental Research and Public Health*, vol. 18, 2021. DOI: 10.3390/ijerph18189668.

- [67] H. S. G. Pussewalage e V. Oleshchuk, «Privacy preserving mechanisms for enforcing security and privacy requirements in E-health solutions», *Int. J. Inf. Manag.*, vol. 36, pp. 1161–1173, 2016. DOI: 10.1016/j.ijinfomgt.2016.07.006.
- [68] G. Gürsel, «Patient Privacy and Security in E-Health», pp. 553–566, 2017. DOI: 10.4018/978-1-5225-0920-2.CH033.
- [69] L. Zhang, Y. Zhang, S. Tang e H. Luo, «Privacy Protection for E-Health Systems by Means of Dynamic Authentication and Three-Factor Key Agreement», *IEEE Transactions on Industrial Electronics*, vol. 65, pp. 2795–2805, 2018. DOI: 10.1109/TIE.2017.2739683.
- [70] F. Amato, V. Casola, G. Cozzolino, A. D. Benedictis, N. Mazzocca e F. Moscato, «A Security and Privacy Validation Methodology for e-Health Systems», *ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)*, vol. 17, pp. 1–22, 2021. DOI: 10.1145/3412373.
- [71] X. Yin, K. Ho, D. Zeng, U. Aickelin, R. Zhou e H. Wang, «Health Information Science», 2015. DOI: 10.1007/978-3-319-19156-0.
- [72] R. M. K. Mohamed, O. R. Shahin, N. O. Hamed, H. Zahran e M. Abdellattif, «Analyzing the Patient Behavior for Improving the Medical Treatment Using Smart Healthcare and IoT-Based Deep Belief Network», *Journal of Healthcare Engineering*, 2022. DOI: 10.1155/2022/6389069.
- [73] S. Majumder, T. Mondal e M. J. Deen, «Wearable Sensors for Remote Health Monitoring», *Sensors*, vol. 17, n.º 1, 2017. DOI: 10.3390/s170100130.
- [74] A. Pantelopoulos e N. G. Bourbakis, «A Survey on Wearable Sensor-Based Systems for Health Monitoring and Prognosis», *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, vol. 40, n.º 1, pp. 1–12, 2010. DOI: 10.1109/TSMCC.2009.2032660.

- [75] W. Polonsky, D. Hessler, K. Ruedy e R. Beck, «The Impact of Continuous Glucose Monitoring on Markers of Quality of Life in Adults With Type 1 Diabetes: Further Findings From the DIAMOND Randomized Clinical Trial», *Diabetes Care*, vol. 40, pp. 736–741, 2017. DOI: 10.2337/dc17-0133.
- [76] E. Hommel, B. Olsen, T. Battelino, I. Conget, I. Schütz-Fuhrmann, R. Hoogma, U. Schierloh, N. Sulli, H. Gough, J. Castañeda, S. Portu, J. Bolinder e the Sgc Nis Study Group, «Impact of continuous glucose monitoring on quality of life, treatment satisfaction, and use of medical care resources: analyses from the SWITCH study», *Acta Diabetologica*, vol. 51, pp. 845–851, 2014. DOI: 10.1007/s00592-014-0598-7.
- [77] B. Liu, H. Wu e G. Wang, «Live Demonstration: A Smart Ring for Continuous Health Data Monitoring Based on Photoplethysmography», *2023 IEEE 5th International Conference on Artificial Intelligence Circuits and Systems (AICAS)*, pp. 1–3, 2023. DOI: 10.1109/AICAS57966.2023.10168644.
- [78] J. D. Ummel, O. S. Hoilett, B. D. Walters, N. D. P. Bluhm, A. S. Pickering, D. A. Wilson e J. Linnes, «Kick Ring LL: A Multi-Sensor Ring Capturing Respiration, Electrocardiogram, Oxygen Saturation, and Skin Temperature1», *2020 42nd Annual International Conference of the IEEE Engineering in Medicine Biology Society (EMBC)*, pp. 4394–4397, 2020. DOI: 10.1109/EMBC44109.2020.9176654.
- [79] G. Yang e Y. Xie, «Advances in Wearable Sensor-Based Health Monitoring Systems», *Advanced Materials Technologies*, vol. 29, n.º 24, 2014. DOI: 10.1002/admt.201400215.
- [80] L. Piwek, D. A. Ellis, S. Andrews e A. Joinson, «The Rise of Consumer Health Wearables: Promises and Barriers», *PLoS Medicine*, vol. 13, n.º 2, e1001953, 2016. DOI: 10.1371/journal.pmed.1001953.
- [81] N. Hossain et al., «Factors Influencing Rural End-Users’ Acceptance of e-Health in Developing Countries: A Study on Portable Health Clinic in Bangladesh», *Telemedicine Journal and e-Health*, 2019. DOI: 10.1089/tmj.2018.0039.

- [82] E.-M. Schomakers et al., «Listen to My Heart? How Privacy Concerns Shape Users' Acceptance of e-Health Technologies», *2019 International Conference on Wireless and Mobile Computing, Networking and Communications (WiMob)*, 2019. DOI: 10.1109/WiMOB.2019.8923448.
- [83] B. Raphiphatthana et al., «Evaluation of a three-phase implementation program in enhancing e-mental health adoption within Indigenous primary healthcare organisations», *BMC Health Services Research*, 2020. DOI: 10.1186/s12913-020-05431-y.
- [84] V. Jagadeeswari, V. Subramaniaswamy, L. Ravi e V. Vijayakumar, «A study on medical Internet of Things and Big Data in personalized healthcare system», *Health Information Science and Systems*, vol. 6, pp. 1–20, 2018. DOI: 10.1007/s13755-018-0049-x.
- [85] A. Bourek, «How to Make Your Work Really Influence Future Healthcare: From Projects Through Policies to Integration Into Health Systems», *IGI Global*, pp. 271–296, 2017. DOI: 10.4018/978-1-5225-1724-5.CH016.
- [86] P. Ruotsalainen, «Privacy, Trust and Security in Two-Sided Markets», *Elsevier*, pp. 65–89, 2017. DOI: 10.1016/B978-0-12-805250-1.00005-8.
- [87] M. Kim, «Conceptualization of e-servicescapes in the fitness applications and wearable devices context: Multi-dimensions, consumer satisfaction, and behavioral intention», *Journal of Retailing and Consumer Services*, 2021. DOI: 10.1016/J.JRETCONSER.2021.102562.
- [88] M. Muzny, A. Henriksen, A. Giordanengo, J. Mužík, A. Grøttland, H. Blixgård, G. Hartvigsen e E. Årsand, «Wearable sensors with possibilities for data exchange: Analyzing status and needs of different actors in mobile health monitoring systems», *International journal of medical informatics*, vol. 133, p. 104017, 2019. DOI: 10.1016/j.ijmedinf.2019.104017.

- [89] Garmin, *Vivoactive 3*, Disponível em: <https://www.garmin.com/pt-PT/p/571520>, 2023.
- [90] *Fitbit Versa Smartwatches*, <https://www.fitbit.com/global/us/products/smartwatches/versa>, Acesso em: 2 de fevereiro de 2024.
- [91] *Polar Vantage V3*, <https://www.polar.com/pt/vantage/v3/explore>, Acesso em: 2 de fevereiro de 2024.
- [92] *Samsung Galaxy Watch 6*, <https://www.samsung.com/pt/watches/galaxy-watch/galaxy-watch6-40mm-gold-bluetooth-sm-r930nzeaphe/>, Acesso em: 5 de fevereiro de 2024.
- [93] *Apple Watch Series 9*, <https://www.apple.com/pt/apple-watch-series-9/>, Acesso em: 5 de fevereiro de 2024.
- [94] C. Karmen, M. A. Reisfeld, M. K. McIntyre, R. Timmermans e W. Frishman, «The Clinical Value of Heart Rate Monitoring Using an Apple Watch», *Cardiology in Review*, vol. 27, pp. 60–62, 2019. DOI: 10.1097/CRD.0000000000000243.
- [95] T. Liang e Y. Yuan, «Wearable Medical Monitoring Systems Based on Wireless Networks: A Review», *IEEE Sensors Journal*, vol. 16, pp. 8186–8199, 2016. DOI: 10.1109/JSEN.2016.2597312.
- [96] U. Reimer, E. Laurenzi, E. Maier e T. Ulmer, «Mobile Stress Recognition and Relaxation Support with SmartCoping: User-Adaptive Interpretation of Physiological Stress Parameters», pp. 1–10, 2017. DOI: 10.24251/HICSS.2017.435.
- [97] A. Géron, *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. O’Reilly Media, 2019.
- [98] D. Greenfeld e A. Roy, *Two Scoops of Django: Best Practices for Django 1.6*. Two Scoops Press, 2014.
- [99] J. Nielsen e R. Budiu, *Mobile Usability*. New Riders, 2013.

- [100] J.-H. Wu, H.-Y. Kao e V. Sambamurthy, «The integration effort and E-health compatibility effect and the mediating role of E-health synergy on hospital performance», *Int. J. Inf. Manag.*, vol. 36, pp. 1288–1300, 2016. DOI: 10.1016/j.ijinfomgt.2016.09.002.
- [101] A. Golpayegani, F. Parand e S. Ashrafiyan, «Standards Development of mHealth at a Glance», *shiraz e medical journal*, vol. 19, 2017. DOI: 10.5812/semj.66313.
- [102] I. Chouvarda, D. Goulis, I. Lambrinouadaki e N. Maglaveras, «Connected health and integrated care: Toward new models for chronic disease management», *Maturitas*, vol. 82 1, pp. 22–7, 2015. DOI: 10.1016/j.maturitas.2015.03.015.
- [103] I. Péntek e A. Adamkó, «Bio-sensory data warehouse with analytics for e-health solutions», em *2019 10th IEEE International Conference on Cognitive Infocommunications (CogInfoCom)*, IEEE, 2019, pp. 169–174. DOI: 10.1109/CogInfoCom47531.2019.9089914.
- [104] K. Clark e C. Baldwin, «The Option Value of Modularity in Design: An Example From Design Rules, Volume 1: The Power of Modularity», *delete*, 2000. DOI: 10.2139/ssrn.312404.
- [105] A. Girgis, I. Durcinoska, A. Arnold e G. Delaney, «Interpreting and Acting on the PRO Scores From the Patient-reported Outcomes for Personalized Treatment and Care (PROMPT-Care) eHealth System», *Medical Care*, vol. 57, S85–S91, 2019. DOI: 10.1097/MLR.0000000000001094.
- [106] N. Abul-Husn e E. Kenny, «Personalized Medicine and the Power of Electronic Health Records», *Cell*, vol. 177, pp. 58–69, 2019. DOI: 10.1016/j.cell.2019.02.039.
- [107] *Garmin Support*, <https://support.garmin.com/en-US/?faq=q22kMdCbU23NUT2Wmspz16>, Accessed on: 2024-02-29, 2024.
- [108] D. I. One, *O que é uma API e como ela funciona?*, <https://www.dio.me/articles/o-que-e-uma-api-Y8U6UW>, Acesso em: 20 de janeiro de 2024, 2021.

- [109] A. E. Malki, U. Zdun e C. Pautasso, «Impact of API Rate Limit on Reliability of Microservices-Based Architectures», *2022 IEEE International Conference on Service-Oriented System Engineering (SOSE)*, pp. 19–28, 2022. DOI: 10.1109/SOSE55356.2022.00009.
- [110] E. Dooley, N. Golaszewski e J. Bartholomew, «Estimating Accuracy at Exercise Intensities: A Comparative Study of Self-Monitoring Heart Rate and Physical Activity Wearable Devices», *JMIR mHealth and uHealth*, vol. 5, 2017. DOI: 10.2196/mhealth.7043.
- [111] S. E. Stahl, H.-S. An, D. Dinkel, J. Noble e J.-M. Lee, «How accurate are the wrist-based heart rate monitors during walking and running activities? Are they accurate enough?», *BMJ Open Sport — Exercise Medicine*, vol. 2, 2016. DOI: 10.1136/bmjsem-2015-000106.
- [112] J. Xie, D. Wen, L. Liang, Y. Jia, L. Gao e J. Lei, «Evaluating the Validity of Current Mainstream Wearable Devices in Fitness Tracking Under Various Physical Activities: Comparative Study», *JMIR mHealth and uHealth*, vol. 6, 2018. DOI: 10.2196/mhealth.9754.
- [113] D. P. T. Vallejo e A. El Saddik, «Emotional States Detection Approaches Based on Physiological Signals for Healthcare Applications: A Review», pp. 47–74, 2019. DOI: 10.1007/978-3-030-27844-1_4.
- [114] J. A. Dominguez-Jimenez, K. Campo-Landines, J. C. Martínez Santos, E. Delahoz e S. H. C. Ortiz, «A machine learning model for emotion recognition from physiological signals», *Biomed. Signal Process. Control*, vol. 55, 2020. DOI: 10.1016/j.bspc.2019.101646.
- [115] S. Davis, «Ready for Prime Time? Using Normalization Process Theory to Evaluate Implementation Success of Personal Health Records Designed for Decision Making», *Frontiers in Digital Health*, vol. 2, 2020. DOI: 10.3389/fgdth.2020.575951.

- [116] J.-M. Lee, W. Byun, A. Keill, D. Dinkel e Y. Seo, «Comparison of Wearable Trackers' Ability to Estimate Sleep», *International Journal of Environmental Research and Public Health*, vol. 15, 2018. DOI: 10.3390/ijerph15061265.
- [117] D. Fuller, E. Colwell, J. Low, K. Orychock, M. Tobin, B. Simango, R. Buote, D. V. Heerden, H. Luan, K. Cullen, L. Slade e N. G. A. Taylor, «Reliability and Validity of Commercially Available Wearable Devices for Measuring Steps, Energy Expenditure, and Heart Rate: Systematic Review», *JMIR mHealth and uHealth*, vol. 8, 2020. DOI: 10.2196/18694.
- [118] G. Shin, M. H. Jarrahi, Y. Fei, A. Karami, N. C. L. Gafinowitz, A. Byun e X. Lu, «Wearable activity trackers, accuracy, adoption, acceptance and health impact: A systematic literature review», *Journal of biomedical informatics*, vol. 93, p. 103 153, 2019. DOI: 10.1016/j.jbi.2019.103153.
- [119] L. Fernández-Aguilar, A. Martínez-Rodrigo, J. Moncho-Bogani, A. Fernández-Caballero e J. M. Latorre, «Emotion Detection in Aging Adults Through Continuous Monitoring of Electro-Dermal Activity and Heart-Rate Variability», pp. 252–261, 2019. DOI: 10.1007/978-3-030-19591-5_26.
- [120] G. J. Nalepa, K. Kutt e S. Bobek, «Mobile platform for affective context-aware systems», *Future Gener. Comput. Syst.*, vol. 92, pp. 490–503, 2019. DOI: 10.1016/J.FUTURE.2018.02.033.
- [121] D. Ç. Ertugrul e A. Elçi, «A survey on semanticized and personalized health recommender systems», *Expert Systems*, vol. 37, 2019. DOI: 10.1111/exsy.12519.
- [122] R. Sharma, S. Rani e D. Gupta, «Stress Detection Using Machine Learning Classifiers in Internet of Things Environment», *Journal of Computational and Theoretical Nanoscience*, 2019. DOI: 10.1166/jctn.2019.8502.
- [123] X. Liu, B. Gao, B. Suleiman, H. You, Z. Ma, Y. Liu e A. Anaissi, «Privacy-Preserving Personalized Fitness Recommender System (P3FitRec): A Multi-level

- Deep Learning Approach», *ACM Transactions on Knowledge Discovery from Data*, 2022. DOI: 10.1145/3572899.
- [124] J. Mulani, S. Heda, K. Tumdi, J. Patel, H. Chhinkaniwala e J. Patel, «Deep Reinforcement Learning Based Personalized Health Recommendations», 2019. DOI: 10.1007/978-3-030-33966-1_12.
- [125] A. Denovan e A. Macaskill, «Building resilience to stress through leisure activities: a qualitative analysis», *Annals of Leisure Research*, vol. 20, pp. 446–466, 2017. DOI: 10.1080/11745398.2016.1211943.
- [126] M. Zawadzki, J. Smyth e H. J. Costigan, «Real-Time Associations Between Engaging in Leisure and Daily Health and Well-Being», *Annals of Behavioral Medicine*, vol. 49, pp. 605–615, 2015. DOI: 10.1007/s12160-015-9694-3.
- [127] M. Goyal, S. Singh, E. M. S. Sibinga, N. F. Gould, A. Rowland-Seymour, R. Sharma, Z. Berger, D. Sleicher, D. D. Maron, H. M. Shihab et al., «Meditation programs for psychological stress and well-being: a systematic review and meta-analysis», *JAMA internal medicine*, vol. 174, n.º 3, pp. 357–368, 2014. DOI: 10.1001/jamainternmed.2013.13018.
- [128] H. Cramer, R. Lauche, J. Langhorst e G. Dobos, «Yoga for anxiety: A systematic review and meta-analysis of randomized controlled trials», *Depression and anxiety*, vol. 30, n.º 9, pp. 827–835, 2013. DOI: 10.1002/da.22166.
- [129] J. Rushing, «Evidence-based Music Therapy Treatment to Elevate Mood During Acute Stroke Care», 2019. DOI: 10.13023/etd.2019.354.
- [130] T. Fritz, J. Halfpaap, S. Grahl, A. Kirkland e A. Villringer, «Musical feedback during exercise machine workout enhances mood», *Frontiers in Psychology*, vol. 4, 2013. DOI: 10.3389/fpsyg.2013.00921.
- [131] E. Artemiou, G. Gilbert, F. Sithole e L. Koster, «The Effects of Music during a Physical Examination Skills Practice: A Pilot Study», *Veterinary Sciences*, vol. 4, 2017. DOI: 10.3390/vetsci4040048.

- [132] P. Fauquet-Alekhine, L. Rouillac, J. Berton e J. Granry, «Heart rate vs stress indicator for short term mental stress», *British journal of medicine and medical research*, vol. 17, pp. 1–11, 2016. DOI: 10.9734/BJMMR/2016/27593.
- [133] Y. Kayacan, Y. Makaracı, C. Uçar, W. Amonette e S. Yıldız, «Heart Rate Variability and Cortisol Levels Before and After a Brief Anaerobic Exercise in Handball Players.», *Journal of strength and conditioning research*, 2023. DOI: 10.1519/JSC.0000000000004411.
- [134] N. Ahmadi, F. Sasangohar, T. Nisar, V. Danesh, E. P. Larsen, I. Sultana e R. Bogetti, «Quantifying Occupational Stress in Intensive Care Unit Nurses: An Applied Naturalistic Study of Correlations Among Stress, Heart Rate, Electrodermal Activity, and Skin Temperature», *Human Factors: The Journal of Human Factors and Ergonomics Society*, vol. 64, pp. 159–172, 2021. DOI: 10.1177/00187208211040889.
- [135] S. P. Carvalho, F. Correa, E. Macau e L. dos Santos, «"Stress Level of Critical Care Nurses: Evaluation by Heart Rate Variability"», *Biomedical Journal of Scientific and Technical Research*, vol. 4, pp. 001–008, 2018. DOI: 10.26717/BJSTR.2018.04.001068.
- [136] J. Garcia-Aymerich, P. Lange, M. Benet, P. Schnohr e J. Antó, «Regular physical activity modifies smoking-related lung function decline and reduces risk of chronic obstructive pulmonary disease: a population-based cohort study.», *American journal of respiratory and critical care medicine*, vol. 175 5, pp. 458–63, 2007. DOI: 10.1164/RCCM.200607-8960C.
- [137] J. Abramson e V. Vaccarino, «Relationship between physical activity and inflammation among apparently healthy middle-aged and older US adults.», *Archives of internal medicine*, vol. 162 11, pp. 1286–92, 2002. DOI: 10.1001/ARCHINTE.162.11.1286.
- [138] B. Franklin, P. Thompson, S. Al-Zaiti, C. Albert, M. Hivert, B. Levine, F. Lobelo, K. Madan, A. Sharrief e T. Eijsvogels, «Exercise-Related Acute Cardiovascular

- Events and Potential Deleterious Adaptations Following Long-Term Exercise Training: Placing the Risks Into Perspective—An Update: A Scientific Statement From the American Heart Association», vol. 141, e705–e736, 2020. DOI: 10.1161/CIR.0000000000000749.
- [139] M. Wong, E. Lau, J. Wan, S. Cheung, C. Hui e D. Mok, «The interplay between sleep and mood in predicting academic functioning, physical health and psychological health: a longitudinal study.», *Journal of psychosomatic research*, vol. 74 4, pp. 271–7, 2013. DOI: 10.1016/j.jpsychores.2012.08.014.
- [140] M. Khan e R. Aouad, «The Effects of Insomnia and Sleep Loss on Cardiovascular Disease.», *Sleep medicine clinics*, vol. 12 2, pp. 167–177, 2017. DOI: 10.1016/j.jsmc.2017.01.005.
- [141] K. L. Nelson, J. E. Davis e C. Corbett, «Sleep quality: An evolutionary concept analysis.», *Nursing forum*, 2021. DOI: 10.1111/nuf.12659.
- [142] M. Irwin, «Sleep and inflammation in resilient aging», *Interface Focus*, vol. 4, 2014. DOI: 10.1098/rsfs.2014.0009.
- [143] A. Scott, T. L. Webb, M. M.-S. James, G. Rowse e S. Weich, «Improving sleep quality leads to better mental health: A meta-analysis of randomised controlled trials», *Sleep Medicine Reviews*, vol. 60, 2021. DOI: 10.1016/j.smr.2021.101556.
- [144] J. Wang e P. Han, «Adversarial Training-Based Mean Bayesian Personalized Ranking for Recommender System», *IEEE Access*, vol. 8, pp. 7958–7968, 2020. DOI: 10.1109/ACCESS.2019.2963316.
- [145] Z. Su e C. Chen, «Implementation of collaborative filtering algorithm with time attribute», *2020 IEEE 9th Joint International Information Technology and Artificial Intelligence Conference (ITAIC)*, vol. 9, pp. 1554–1558, 2020. DOI: 10.1109/ITAIC49862.2020.9338992.
- [146] J. Wang, Z. Fu, M. Niu, P. Zhang e Q. Zhang, «Multi-feedback Pairwise Ranking via Adversarial Training for Recommender», 2020. DOI: 10.1049.

- [147] L. R. Ferretto e outros, «A Physical Activity Recommender System for Patients With Arterial Hypertension», *IEEE Access*, vol. 8, pp. 61 656–61 664, 2020. DOI: 10.1109/ACCESS.2020.2983564.
- [148] A. Chatterjee, M. W. Gerdes e S. Martinez, «eHealth Initiatives for The Promotion of Healthy Lifestyle and Allied Implementation Difficulties», *2019 International Conference on Wireless and Mobile Computing, Networking and Communications (WiMob)*, pp. 1–8, 2019. DOI: 10.1109/WiMOB.2019.8923324.
- [149] R. Mojarad, F. Attal, A. Chibani e Y. Amirat, «Context-aware Adaptive Recommendation System for Personal Well-being Services», *2020 IEEE 32nd International Conference on Tools with Artificial Intelligence (ICTAI)*, pp. 192–199, 2020. DOI: 10.1109/ICTAI50040.2020.00039.
- [150] A. Gyrard e A. Sheth, «IAMHAPPY: Towards an IoT knowledge-based cross-domain well-being recommendation system for everyday happiness», *Smart Health*, 2020. DOI: 10.1016/j.smhl.2019.100083.
- [151] R. L. Rosa, G. M. Schwartz, W. Ruggiero e D. Z. Rodríguez, «A Knowledge-Based Recommendation System That Includes Sentiment Analysis and Deep Learning», *IEEE Transactions on Industrial Informatics*, vol. 15, pp. 2124–2135, 2019. DOI: 10.1109/TII.2018.2867174.
- [152] V. Chang, M. Ramachandran e C. Li, «Special issue editorial on emerging trends in internet of things for e-health and medical supply chain systems», *Expert Systems*, vol. 39, 2022. DOI: 10.1111/exsy.12870.
- [153] W. Bagunaid, N. Chilamkurti e P. Veeraraghavan, «AISAR: Artificial Intelligence-Based Student Assessment and Recommendation System for E-Learning in Big Data», *Sustainability*, 2022. DOI: 10.3390/su141710551.
- [154] A. Chatterjee e A. Prinz, «Personalized Recommendations for Physical Activity e-Coaching (OntoRecoModel): Ontological Modeling», *JMIR Medical Informatics*, vol. 10, 2022. DOI: 10.2196/33847.

- [155] D. Szinay e outros, «Influences on the Uptake of and Engagement With Health and Well-Being Smartphone Apps: Systematic Review», *Journal of Medical Internet Research*, vol. 22, 2020. DOI: 10.2196/17572.
- [156] S. N. M. F. e outros, «User-Centered Design of a Patient Medication Reconciliation Module in an Integrated Personal Health Record», *Studies in health technology and informatics*, vol. 264, pp. 1278–1282, 2019. DOI: 10.3233/SHTI190432.
- [157] D. K. R. e outros, «Integration of personalized drug delivery systems into digital health», *Advanced drug delivery reviews*, 2021. DOI: 10.1016/j.addr.2021.113857.
- [158] J. F. e outros, «A Human-in-the-Loop Cyber-Physical Approach for Students Performance Assessment», *Proceedings of the Fourth International Workshop on Social Sensing*, 2019. DOI: 10.1145/3313294.3313387.
- [159] V. C. e outros, «Patient-centered Design Grounded in User and Clinical Realities: Towards Valid Digital Health», *Proceedings of the International Symposium of Human Factors and Ergonomics in Healthcare*, 2019. DOI: 10.1177/2327857919081023.
- [160] J. Calvillo-Arbizu, L. M. Roa-Romero, M. A. Estudillo-Valderrama, M. Salgueira-Lazo, N. Areste-Fosalba, N. L. del-Castillo-Rodríguez, F. González-Cabrera, S. Marrero-Robayna, V. López-de-la-Manzana e I. Roman-Martinez, «User-centred design for developing e-Health system for renal patients at home (AppNephro)», *International journal of medical informatics*, vol. 125, pp. 47–54, 2019. DOI: 10.1016/j.ijmedinf.2019.02.007.
- [161] C. G. e outros, «User-centred co-design with multiple user groups: The case of the electronic Patient Reported Outcome (ePRO) mobile application and portal», *International Journal of Integrated Care*, 2019. DOI: 10.5334/IJIC.S3439.

- [162] R. Y. P. e outros, «Evaluation of Experiences and Impact of Patient Engagement on e-Health Research: A Qualitative Study», *Healthcare quarterly*, 2022. DOI: 10.12927/hcq.2022.26775.
- [163] P. Jovanovic e R. Kay, «Exploring Ethical Issues with Using Wearable Technology in K-12 Classrooms: A Review of the Literature», *Journal of Digital Life and Learning*, 2023. DOI: 10.51357/jd11.v2i2.203.
- [164] R. Y. Pan, K. Zhang, A. Sivakumar, D. Choi, A. Wang, P. Wijeyesekera e C. Yu, «Evaluation of Experiences and Impact of Patient Engagement on e-Health Research: A Qualitative Study», *Healthcare quarterly*, vol. 24 SP, pp. 44–48, 2022. DOI: 10.12927/hcq.2022.26775.
- [165] A. Bhatnagar, «Designing health risk assessment report for wellness clinic patients», *European Journal of Public Health*, 2020. DOI: 10.1093/eurpub/ckaa165.580.
- [166] M. Hirshkowitz, K. Whiton, S. M. Albert, C. Alessi, O. Bruni, L. DonCarlos, N. Hazen, J. Herman, P. J. A. Hillard, E. S. Katz, L. Kheirandish-Gozal, D. N. Neubauer, A. E. O'Donnell, M. Ohayon, J. Peever, R. Rawding, R. R. Rosa, J. A. Siegel, D. J. Skene, M. R. Pressman e L. Hale, «National Sleep Foundation's sleep time duration recommendations: methodology and results summary», *Sleep Health*, vol. 1, n.º 1, pp. 40–43, 2015. DOI: 10.1016/j.sleh.2014.12.010.
- [167] M. M. Ohayon, M. A. Carskadon, C. L. Guilleminault e M. V. Vitiello, «Nocturnal awakenings and comorbid disorders in the American general population», *Journal of Psychiatric Research*, vol. 64, pp. 59–66, 2017. DOI: 10.1016/j.jpsychires.2015.03.004.
- [168] N. F. Watson, M. S. Badr, G. Belenky, D. L. Bliwise, O. M. Buxton, D. Buysse, D. F. Dinges, J. Gangwisch, M. A. Grandner, C. Kushida, R. K. Malhotra, J. L. Martin, S. R. Patel, S. F. Quan e E. Tasali, «Recommended Amount of Sleep for a Healthy Adult: A Joint Consensus Statement of the American Academy of Sleep

- Medicine and Sleep Research Society», *Sleep*, vol. 38, n.º 6, pp. 843–844, 2015. DOI: 10.5665/sleep.4716.
- [169] D. J. Buysse, C. F. R. III, T. H. Monk, S. R. Berman e D. J. Kupfer, «The Pittsburgh Sleep Quality Index: A new instrument for psychiatric practice and research», *Psychiatry Research*, vol. 28, n.º 2, pp. 193–213, 1989. DOI: 10.1016/0165-1781(89)90047-4.
- [170] C. Tudor-Locke, C. Craig, Y. Aoyagi, R. Bell, K. Croteau, I. de Bourdeaudhuij, B. Ewald, A. Gardner, Y. Hatano, L. Lutes, S. Matsudo, F. Ramírez-Marrero, L. Rogers, D. Rowe, M. D. Schmidt, M. Tully e S. Blair, «How many steps/day are enough? For older adults and special populations», *The International Journal of Behavioral Nutrition and Physical Activity*, vol. 8, pp. 80–80, 2011. DOI: 10.1186/1479-5868-8-80.
- [171] R. Rosenkranz, M. Duncan, C. Caperchione, G. Kolt, C. Vandelanotte, A. Maeder, T. Savage e W. Mummery, «Validity of the Stages of Change in Steps instrument (SoC-Step) for achieving the physical activity goal of 10,000 steps per day», *BMC Public Health*, vol. 15, 2015. DOI: 10.1186/s12889-015-2539-y.
- [172] K. Hallam, S. Bilsborough e M. D. de Courten, «“Happy feet”: evaluating the benefits of a 100-day 10,000 step challenge on mental health and wellbeing», *BMC Psychiatry*, vol. 18, 2018. DOI: 10.1186/s12888-018-1609-y.
- [173] C. Tudor-Locke, Y. Hatano, R. Pangrazi e M. Kang, «Revisiting "how many steps are enough?"», *Medicine and science in sports and exercise*, vol. 40, n.º 7 Suppl, S537–43, 2008. DOI: 10.1249/MSS.0b013e31817c7133.
- [174] S. Keadle, L. Meuter, S. Phelan e S. M. Phillips, «Charity-based incentives motivate young adult cancer survivors to increase physical activity: a pilot randomized clinical trial», *Journal of Behavioral Medicine*, vol. 44, pp. 682–693, 2021. DOI: 10.1007/s10865-021-00218-w.

- [175] J. F. Gavin, M. Keough, M. Abravanel, T. Moudrakovski e M. Mcbrearty, «Motivations for participation in physical activity across the lifespan», *International Journal of Wellbeing*, vol. 4, pp. 46–61, 2014. DOI: 10.5502/IJW.V4I1.3.
- [176] J. K. et al., «Energy expenditure estimation in beta-blocker-medicated cardiac patients by combining heart rate and body movement data», *European Journal of Preventive Cardiology*, 2016. DOI: 10.1177/2047487316667786.
- [177] Í. A. P. M. et al., «Fractal correlations and linear analyses of heart rate variability in healthy young people with different levels of physical activity», *Cardiology in the Young*, 2019. DOI: 10.1017/S1047951119001793.
- [178] G. O. et al., «Context-Aware Approach for Cardiac Rehabilitation Monitoring», 2020. DOI: 10.3233/AISE200039.
- [179] J. C. F. et al., «ISABELA - A Socially-Aware Human-in-the-Loop Advisor System», *Online Soc. Networks Media*, 2020. DOI: 10.1016/j.osnem.2020.100060.
- [180] C. C. de Jong et al., «The challenge of involving elderly patients in primary care using an electronic communication tool with their professionals: a mixed methods study», *BMJ Health Care Informatics*, 2017. DOI: 10.14236/jhi.v24i3.937.
- [181] B. S. et al., «Self-Reflective Sentiment Analysis», *Proceedings of the 3rd Workshop on Computational Linguistics and Clinical Psychology*, pp. 23–32, 2016. DOI: 10.18653/v1/W16-0303.
- [182] B. E. et al., «Protocol for a mixed-methods realist evaluation of a health service user feedback system in Bangladesh», *BMJ Open*, vol. 7, 2017. DOI: 10.1136/bmjopen-2017-017743.
- [183] T. Vrijkotte, L. V. van Doornen e E. D. de Geus, «Effects of work stress on ambulatory blood pressure, heart rate, and heart rate variability.», *Hypertension*, vol. 35 4, pp. 880–6, 2000. DOI: 10.1161/01.HYP.35.4.880.

- [184] V. Mishra, G. Pope, S. E. Lord, S. Lewia, B. M. Lowens, K. E. Caine, S. Sen, R. Halter e D. Kotz, «Continuous Detection of Physiological Stress with Commodity Hardware», *ACM Transactions on Computing for Healthcare*, vol. 1, pp. 1–30, 2020. DOI: 10.1145/3361562.
- [185] M. Kumar, S. Neubert, S. Behrendt, A. Rieger, M. Weippert, N. Stoll, K. Thurow e R. Stoll, «Stress Monitoring Based on Stochastic Fuzzy Analysis of Heartbeat Intervals», *IEEE Transactions on Fuzzy Systems*, vol. 20, pp. 746–759, 2012. DOI: 10.1109/TFUZZ.2012.2183602.
- [186] M. X. Hu, Y. Milaneschi, F. Lamers, I. Nolte, H. Snieder, C. Dolan, B. Penninx e E. D. de Geus, «The association of depression and anxiety with cardiac autonomic activity: The role of confounding effects of antidepressants», *Depression and Anxiety*, vol. 36, pp. 1163–1172, 2019. DOI: 10.1002/da.22966.
- [187] S. Nagy, S. M. Pickett, M. Hedge, J. Mesa e R. Mechal, «0165 The Relationship Between Anxiety Symptoms and Sleep Quality: Mediating and Moderating Factors of Pre-Sleep Arousal and Anxiety Sensitivity», *Sleep*, vol. 43, 2020. DOI: 10.1093/sleep/zsaa056.163.
- [188] A. Richards, J. Kanady e T. Neylan, «Sleep disturbance in PTSD and other anxiety-related disorders: an updated review of clinical features, physiological characteristics, and psychological and neurobiological mechanisms», *Neuropsychopharmacology*, vol. 45, pp. 55–73, 2019. DOI: 10.1038/s41386-019-0486-5.
- [189] G. Pires, A. Bezerra, S. Tufik e M. Andersen, «Effects of acute sleep deprivation on state anxiety levels: a systematic review and meta-analysis.», *Sleep medicine*, vol. 24, pp. 109–118, 2016. DOI: 10.1016/j.sleep.2016.07.019.
- [190] M. Shirai e N. Suzuki, «Physiological Changes in Response to the Feelings of Sadness Induced by Two Different Situations», vol. 34, pp. 203–212, 2016. DOI: 10.5674/JJPPP.1614BR.

- [191] T. Crönlein, B. Langguth, P. Eichhammer e V. Busch, «Impaired Recognition of Facially Expressed Emotions in Different Groups of Patients with Sleep Disorders», *PLoS ONE*, vol. 11, n.º 4, e0152754, 2016. DOI: 10.1371/journal.pone.0152754.
- [192] J. Sibold, E. Edwards, D. Murray-Close e J. Hudziak, «Physical activity, sadness, and suicidality in bullied US adolescents.», *Journal of the American Academy of Child and Adolescent Psychiatry*, vol. 54 10, pp. 808–15, 2015. DOI: 10.1016/j.jaac.2015.06.019.
- [193] A. Mustaqeem, S. Anwar, A. Khan e M. Majid, «A statistical analysis based recommender model for heart disease patients», *International journal of medical informatics*, vol. 108, pp. 134–145, 2017. DOI: 10.1016/j.ijmedinf.2017.10.008.
- [194] M. Lambay e S. Mohideen, «A Hybrid Approach Based Diet Recommendation System Using ML and Big Data Analytics», *J. Mobile Multimedia*, vol. 18, 2022. DOI: 10.13052/jmm1550-4646.1864.
- [195] S. Suresh, N. Kumar e R. Shyamasundar, «Enforcing Secure Data Sharing in Web Application Development Frameworks Like Django Through Information Flow Control», pp. 551–561, 2015. DOI: 10.1007/978-3-319-26961-0_34.
- [196] L. Giannopoulos, E. Degkleri, P. Tsanakas e D. Mitropoulos, «Pythia: Identifying Dangerous Data-flows in Django-based Applications», *Proceedings of the 12th European Workshop on Systems Security*, 2019. DOI: 10.1145/3301417.3312497.
- [197] K. Duisebekova, R. Khabirov e A. Zholzhan, «DJANGO AS SECURE WEB-FRAMEWORK IN PRACTICE», 2021. DOI: 10.52167/1609-1817-2021-116-1-275-281.
- [198] C. E. da Silva, W. D. Medeiros e S. Sampaio, «PEP4Django A Policy Enforcement Point for Python Web Applications», *Anais do IX Workshop de Gestão de Identidades Digitais (WGID 2019)*, 2019. DOI: 10.5753/wgid.2019.14021.
- [199] J. Feigenbaum, M. Liberman e R. Wright, «Cryptographic Protection of Databases and Software», pp. 161–172, 1989. DOI: 10.1090/dimacs/002/10.

- [200] P. Kumar e S. Rana, «Development of modified AES algorithm for data security», *Optik*, vol. 127, pp. 2341–2345, 2016. DOI: 10.1016/J.IJLEO.2015.11.188.
- [201] M. Clark e A. Doryab, «Sounds of Health: Using Personalized Sonification Models to Communicate Health Information», *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, vol. 6, pp. 1–31, 2022. DOI: 10.1145/3570346.
- [202] Y. Zgueb et al., «Staff Perception of Respect for Human Rights of Users and Organizational Well-being: A Study in Four Different Countries of the Mediterranean Area», *Clinical Practice and Epidemiology in Mental Health : CP & EMH*, vol. 16, pp. 109–114, 2020. DOI: 10.2174/1745017902016010109.
- [203] J. Grossmeier et al., «Workplace Well-Being Factors That Predict Employee Participation, Health and Medical Cost Impact, and Perceived Support», *American Journal of Health Promotion*, vol. 34, pp. 349–358, 2020. DOI: 10.1177/0890117119898613.
- [204] S. Katariya, J. Bose, M. V. Reddy, A. Sharma e S. Tappashetty, «A Personalized Health Recommendation System Based on Smartphone Calendar Events», pp. 110–120, 2018. DOI: 10.1007/978-3-319-94523-1_10.
- [205] R. Ali, M. Afzal, M. Hussain, M. Ali, M. H. Siddiqi, S. Lee e B. Kang, «Multimodal hybrid reasoning methodology for personalized wellbeing services», *Computers in biology and medicine*, vol. 69, pp. 10–28, 2016. DOI: 10.1016/j.combiomed.2015.11.013.
- [206] N. Nag, V. Pandey e R. C. Jain, «Live Personalized Nutrition Recommendation Engine», em *Proceedings of the 2nd International Workshop on Multimedia for Personal Health and Health Care*, 2017. DOI: 10.1145/3132635.3132643.
- [207] W. Scherz, R. Seepold, N. M. Madrid, P. Crippa, G. Biagetti, L. Falaschetti e C. Turchetti, «Activity Monitoring and Phase Detection Using a Portable EMG/ECG System», pp. 187–194, 2018. DOI: 10.1007/978-3-030-11973-7_22.

- [208] M. Mücke, S. Ludyga, F. Colledge e M. Gerber, «Influence of Regular Physical Activity and Fitness on Stress Reactivity as Measured with the Trier Social Stress Test Protocol: A Systematic Review», *Sports Medicine*, vol. 48, n.º 11, pp. 2607–2622, 2018. DOI: 10.1007/s40279-018-0979-0.
- [209] T. Semplonius e T. Willoughby, «Long-Term Links between Physical Activity and Sleep Quality», *Medicine Science in Sports Exercise*, vol. 50, pp. 2418–2424, 2018. DOI: 10.1249/MSS.0000000000001706.
- [210] V. Bachmann, F. Klaus, S. Bodenmann, N. Schäfer, P. Brugger, S. Huber, W. Berger e H. Landolt, «Functional ADA polymorphism increases sleep depth and reduces vigilant attention in humans.», *Cerebral cortex*, vol. 22 4, pp. 962–70, 2012. DOI: 10.1093/cercor/bhr173.
- [211] J. Linardon, P. Cuijpers, P. Carlbring, M. Messer e M. Fuller-Tyszkiewicz, «Can mobile health interventions reduce anxiety and depression? A meta-analysis of randomized controlled trials», *Psychological Medicine*, vol. 50, n.º 2, pp. 246–258, 2020. DOI: 10.1017/S0033291719002511.
- [212] M. A. Whooley e A. L. Boyd, «The role of digital health interventions in the management of physical and mental health conditions», *Journal of Medical Internet Research*, vol. 21, n.º 4, e12831, 2019. DOI: 10.2196/12831.
- [213] B. K. Pedersen e B. Saltin, «Effects of physical exercise on anxiety, depression, and sensitivity to stress: A unifying theory», *Clinical and Experimental Pharmacology and Physiology*, vol. 46, n.º 1, pp. 52–62, 2019. DOI: 10.1111/1440-1681.13053.
- [214] J. Leenen, C. Leertveld, J. D. van Dijk, H. V. van Westreenen, L. Schoonhoven e G. Patijn, «Current Evidence for Continuous Vital Signs Monitoring by Wearable Wireless Devices in Hospitalized Adults: Systematic Review», *Journal of Medical Internet Research*, vol. 22, 2020. DOI: 10.2196/18636.

- [215] M. S. Patel, D. A. Asch e K. G. Volpp, «Wearable Devices as Facilitators, Not Drivers, of Health Behavior Change», *JAMA*, vol. 313, n.º 5, pp. 459–460, 2015. DOI: 10.1001/jama.2014.14781.
- [216] X. Li, J. Dunn, D. Salins, G. Zhou, W. Zhou, S. M. Schüssler-Fiorenza Rose, D. Perelman, E. Colbert, R. Runge, S. Rego, R. Sonecha, S. Datta, T. McLaughlin e M. P. Snyder, «The Impact of Wearable Sensor Technologies on Improvements in Health and Health Care Outcomes: A Systematic Review», *Sensors*, vol. 18, n.º 10, p. 3304, 2018. DOI: 10.3390/s18103304.
- [217] M. Swan, «Health 2050: The Realization of Personalized Medicine through Crowdsourcing, the Quantified Self, and the Participatory Biocitizen», *Journal of Personalized Medicine*, vol. 2, n.º 3, pp. 93–118, 2012. DOI: 10.3390/jpm2030093.
- [218] A. C. Yang, F. Kern, P. M. Losada, A. Aguzzi, W. Moritz e W. Karlen, «Wearable Technologies for Developing Sleep and Circadian Biomarkers: A Summary of Workshop Discussions», *Sleep*, vol. 42, n.º 2, 2019. DOI: 10.1093/sleep/zsy213.
- [219] L. G. Park, J. Howie-Esquivel e M. A. Whooley, «Emerging Technologies for Heart Health: Digital Health Tools, Wearables, and Heart Rate Apps», *Current Cardiology Reports*, vol. 22, n.º 11, 2020. DOI: 10.1007/s11886-020-01382-2.
- [220] K. Guk, G. Han, J. Lim e K. Jeong, «The Role of Wearable Devices in Meeting the Needs of Cloud Healthcare: Opportunities and Challenges», *IEEE Cloud Computing*, vol. 6, n.º 3, pp. 45–55, 2019. DOI: 10.1109/MCC.2019.2915280.
- [221] L. Weeks, J. Polisena, A. Scott, A. Holtorf, S. Staniszevska e K. Facey, «Evaluation Of Patient and Public Involvement Initiatives in Health Technology Assessment: A Survey of International Agencies», *International Journal of Technology Assessment in Health Care*, vol. 33, pp. 715–723, 2017. DOI: 10.1017/S0266462317000976.

Apêndice A

Códigos desenvolvidos no Capítulo 4

Desenvolvimento dos códigos

```
1  Conexao com a API do Garmin}{python}
2
3  # Arquivo de autenticação garmin
4  from garminconnect import Garmin
5
6  def fetch_garmin_data(email, password):
7      client = Garmin(email, password)
8      try:
9          client.login()
10         return client
11     except Exception as e:
12         print(f"Erro ao conectar: {e}")
13         return None
14
15
16 # Função para escrever os dados no banco de dados do InfluxDB
17 def write_health_data(measurement, tags, fields, timestamp):
18     with InfluxDBClient(
19         url=settings.INFLUXDB['url'],
20         token=settings.INFLUXDB['token'],
21         org=settings.INFLUXDB['org']
22     ) as client:
```

```

23     write_api = client.write_api(write_options=WriteOptions(batch_size=1,
24     flush_interval=10_000))
25     point = Point(measurement)
26     for tag_key, tag_value in tags.items():
27         point.tag(tag_key, tag_value)
28     for field_key, field_value in fields.items():
29         point.field(field_key, field_value)
30     point.time(timestamp)
31     write_api.write(bucket=settings.INFLUXDB['bucket'], record=point)
32
33
34     # Função para ler os dados de sono do banco de dados do Influxdb
35     def get_sleep_data(self, user, date):
36         start_date = (datetime.fromisoformat(date) -
37         timedelta(days=1)).strftime('%Y-%m-%dT20:00:00Z')
38         end_date = datetime.fromisoformat(date).strftime('%Y-%m-%dT23:59:59Z')
39
40         sleep_data = {
41             "deep": 0,
42             "light": 0,
43             "rem": 0,
44             "awake": 0
45         }
46
47         for sleep_type in ["deep", "light", "rem", "awake"]:
48             query = f'''
49             from(bucket: "{settings.INFLUXDB['bucket']}")
50             |> range(start: {start_date}, stop: {end_date})
51             |> filter(fn: (r) => r["_measurement"] == "sleep" and
52             r["user"] == "{user}" and r["_field"] == "{sleep_type}")
53             |> last()
54             '''
55             tables = self.client.query_api().query(org=settings.INFLUXDB['org'],
56             query=query)
57

```

```

58         if tables and len(tables) > 0 and len(tables[0].records) > 0:
59             latest_sleep_record = tables[0].records[0]
60             sleep_data[sleep_type] = latest_sleep_record.get_value() or 0
61
62         return sleep_data
63
64     # Função que calcula a pontuação do sono
65     def calculate_sleep_score(sleep_data):
66         if not sleep_data:
67             return None
68
69         deep_sleep_seconds = sleep_data.get('deep', 0) * 60
70         light_sleep_seconds = sleep_data.get('light', 0) * 60
71         rem_sleep_seconds = sleep_data.get('rem', 0) * 60
72         awake_seconds = sleep_data.get('awake', 0) * 60
73
74         total_sleep_seconds = deep_sleep_seconds + light_sleep_seconds + rem_sleep_seconds
75         total_sleep_hours = total_sleep_seconds / 3600
76
77         duration_score = 0
78         if 7 <= total_sleep_hours <= 8:
79             duration_score = 100
80         elif 6 <= total_sleep_hours < 7 or 8 < total_sleep_hours <= 9:
81             duration_score = 80
82         else:
83             duration_score = 50
84
85         quality_score = 0
86         if awake_seconds < total_sleep_seconds * 0.1:
87             quality_score = 100
88         elif awake_seconds < total_sleep_seconds * 0.2:
89             quality_score = 80
90         else:
91             quality_score = 50
92

```

```

93     duration_weight = 0.7
94     quality_weight = 0.3
95
96     sleep_score = (duration_score * duration_weight) +
97     (quality_score * quality_weight)
98
99     return round(min(sleep_score, 100))
100
101 # Função que busca os valores do stress fornecidos pelo Garmin no banco de dados
102 def get_stress_data(self, user, date):
103     query = f'''
104         from(bucket: "{settings.INFLUXDB['bucket']}")
105         |> range(start: -1d)
106         |> filter(fn: (r) => r["_measurement"] == "stress" and r["user"] == "{user}")
107         |> keep(columns: ["_value", "_time"])
108         '''
109     tables = self.client.query_api().query(org=settings.INFLUXDB['org'],
110     query=query)
111     stress_levels = [
112         {'level': record.get_value(), 'timestamp': record.get_time().timestamp()}
113         for table in tables for record in table.records
114     ]
115     return stress_levels
116 # Função que calcula e transforma o level de stress do relógio em pontuação de stress
117 def calculate_stress_score(heart_rate_score, sleep_score, activity_score):
118     # Tratando None como 0 para cálculo
119     heart_rate_score = heart_rate_score if heart_rate_score is not None else 0
120     sleep_score = sleep_score if sleep_score is not None else 0
121     activity_score = activity_score if activity_score is not None else 0
122
123     # Calcula o stress_level com os pesos determinados
124     stress_level= (
125         0.2 * heart_rate_score +
126         0.2 * sleep_score +
127         0.6 * activity_score

```

```

128     )
129     return round(stress_level)
130
131     # Função que busca os valores de atividade fornecidos pelo Garmin no banco de dados
132     def get_steps_data(self, user, date):
133         query = f'''
134             from(bucket: "{settings.INFLUXDB['bucket']}")
135             |> range(start: {date}T00:00:00Z, stop: {date}T23:59:59Z)
136             |> filter(fn: (r) => r["_measurement"] == "steps" and r["user"] == "{user}")
137             '''
138         tables = self.client.query_api().query(query)
139         total_steps = sum(record.get_value() for table in
140             tables for record in table.records)
141         return total_steps
142
143     # Função que calcula os valores da pontuação de atividade
144     def calculate_activity_score(total_steps):
145         high_step_goal = 8000
146         medium_step_goal = 5000
147
148         print(f"Total steps: {total_steps}")
149
150         if total_steps >= high_step_goal:
151             return 100
152         elif total_steps >= medium_step_goal:
153             return round(50.0 + (50.0 * (total_steps -
154                 medium_step_goal) / (high_step_goal - medium_step_goal)))
155         else:
156             return round((50.0 * total_steps / medium_step_goal))
157
158     # Função que busca os valores de frequência cardíaca fornecidos no banco de dados
159     def get_heart_rate_data(self, user):
160         now = datetime.utcnow()
161         start_time = (now - timedelta(minutes=30)).strftime('%Y-%m-%dT%H:%M:%SZ')
162         end_time = now.strftime('%Y-%m-%dT%H:%M:%SZ')

```

```

163
164     query = f'''
165         from(bucket: "{settings.INFLUXDB['bucket']}")
166         |> range(start: {start_time}, stop: {end_time})
167         |> filter(fn: (r) => r["_measurement"] ==
168             "heart_rate" and r["user"] == "{user}")
169         |> keep(columns: ["_value", "_time"])
170         '''
171     tables = self.client.query_api().query(query)
172
173     heart_rates = [{'value': record.get_value(), 'time': record.get_time()} for
174         table in tables for record in table.records]
175
176     return heart_rates
177
178 # Função que calcula os valores da pontuação da Frequência Cardíaca
179 def calculate_heart_rate_score(heart_rate_data, steps_data, activity_threshold=500):
180
181     normal_bpm_range = range(60, 100)
182     is_active = False
183
184     current_time_utc = datetime.now(timezone.utc)
185
186     if isinstance(steps_data, list) and all(isinstance(step, dict) for
187         step in steps_data):
188         last_30min_steps = sum(step['steps'] for step in steps_data if 'timestamp' in
189             step and current_time_utc - step['timestamp'] < timedelta(minutes=30))
190         is_active = last_30min_steps > activity_threshold
191
192     elif isinstance(steps_data, int):
193         is_active = steps_data > activity_threshold
194
195     print(f"is_active: {is_active}")
196
197     if is_active:

```

```

198         return 100
199
200     last_30min_heart_rates = [hr for hr in heart_rate_data if current_time_utc -
201     hr['time'] < timedelta(minutes=30)]
202
203     if not last_30min_heart_rates:
204         return None
205
206     abnormal_rates_count = sum(1 for hr in last_30min_heart_rates if
207     hr['value'] not in normal_bpm_range)
208
209     abnormal_rate_penalty = 10 * abnormal_rates_count
210     heart_rate_score = max(0, 100 - abnormal_rate_penalty)
211
212     return round(heart_rate_score)
213
214     # Função que busca os valores do feedback de tristeza do usuário
215     def get_sadness_feedback_data(self, user):
216         query = f'''
217             from(bucket: "{settings.INFLUXDB['bucket']}")
218             |> range(start: -7d)
219             |> filter(fn: (r) => r["_measurement"] == "user_feedback" and
220             r["user"] == "{user}")
221             |> last()
222             '''
223         tables = self.client.query_api().query(query)
224         if tables:
225             for table in tables:
226                 for record in table.records:
227                     return record.get_value()
228         return 0
229
230     # Função que calcula os valores da pontuação do feedback de tristeza
231     def calculate_sadness_feedback_score(sadness_feedback_data):
232         if isinstance(sadness_feedback_data, list) and sadness_feedback_data:

```

```

233     last_feedback = sadness_feedback_data[-1].get('feedback', 0)
234 elif isinstance(sadness_feedback_data, int):
235     last_feedback = sadness_feedback_data
236 else:
237     return None
238
239 normalized_feedback = (10 - last_feedback) / 8
240 sadness_feedback_score = (1 - normalized_feedback) * 100
241
242 return round(sadness_feedback_score)
243
244 # Função que calcula os valores da pontuação da Ansiedade
245 def calculate_anxiety_score(heart_rate_score, sleep_score, activity_score, stress_level):
246     print(f"Calculating Anxiety Score with Heart Rate Score: {heart_rate_score}, Sleep Score: {sleep_score}")
247     # Trate None como 0 para cálculo
248     heart_rate_score = heart_rate_score if heart_rate_score is not None else 0
249     sleep_score = sleep_score if sleep_score is not None else 0
250     activity_score = activity_score if activity_score is not None else 0
251     stress_level = stress_level if stress_level is not None else 0
252
253     anxiety_score = (
254         0.3 * heart_rate_score +
255         0.2 * sleep_score +
256         0.1 * activity_score +
257         0.4 * stress_level
258     )
259     return anxiety_score
260
261 # Função que calcula os valores da pontuação da Tristeza
262 def calculate_sadness_score(heart_rate_score, sleep_score, activity_score,
263 sadness_feedback_score):
264
265     heart_rate_score = heart_rate_score if heart_rate_score is not None else 0
266
267     sleep_score = sleep_score if sleep_score is not None else 0

```

```

268
269     activity_score = activity_score if activity_score is not None else 0
270
271     sadness_feedback_score = sadness_feedback_score if
272     sadness_feedback_score is not None else 0
273
274     sadness_score = (
275         0.3 * heart_rate_score +
276         0.2 * sleep_score +
277         0.1 * activity_score +
278         0.4 * sadness_feedback_score
279     )
280
281     sadness_score = round(min(sadness_score, 100), 2)
282
283     return sadness_score
284
285 # Função que obtem as recomendações do Django Admin
286 def get_recommendations_for_scores(user_scores):
287     recommendations = {}
288     for score_type, score in user_scores.items():
289         rounded_score = round(score)
290
291         try:
292             recommendation = ScoreRecommendation.objects.filter(
293                 Q(score_type=score_type),
294                 Q(min_score__lte=rounded_score),
295                 Q(max_score__gte=rounded_score)
296             ).first()
297
298             if recommendation:
299                 recommendations[score_type] = recommendation.recommendation_text
300         else:
301             recommendation = ScoreRecommendation.objects.filter(
302                 Q(score_type=score_type),

```

```

303         Q(min_score__lt=rounded_score),
304         Q(max_score__gt=rounded_score)
305     ).first()
306     if recommendation:
307         recommendations[score_type] = recommendation.recommendation_text
308     else:
309         recommendations[score_type] = "Não há recomendações disponíveis."
310
311     except ScoreRecommendation.DoesNotExist:
312         recommendations[score_type] = "Não há recomendações disponíveis."
313
314     return recommendations
315
316 # Função do modelo das recomendações
317 from django.db import models
318
319 class ScoreRecommendation(models.Model):
320     score_type = models.CharField(max_length=100)
321     min_score = models.IntegerField(default=0)
322     max_score = models.IntegerField(default=100)
323     recommendation_text = models.TextField()
324
325     def __str__(self):
326         return f"{self.score_type} ({self.min_score}-{self.max_score})"
327
328 # Função de configuração do Django Admin para as recomendações
329 from django.contrib import admin
330 from .models import ScoreRecommendation
331
332 @admin.register(ScoreRecommendation)
333 class RecommendationAdmin(admin.ModelAdmin):
334     list_display = ('score_type', 'min_score', 'max_score', 'recommendation_text')

```

Apêndice B

Código da Página Inicial

```

1  {% extends 'base.html' %}  {# Estende o layout base do HTML definido em 'base.html' #}
2  {% block content %}  {# Define o bloco de conteúdo que será inserido no 'base.html' #}
3
4  {# Este template utiliza o Bootstrap para estilização rápida e responsiva. As classes
5  do Bootstrap ajudam a criar um layout consistente e responsivo, otimizando a
6  interface para diferentes tamanhos de tela. #}
7
8  <div class="container mt-5">
9    <div class="jumbotron text-center py-5">
10     <h1 class="display-4">Bem-vindo ao e-Health</h1>
11     <p class="lead">
12       Descubra insights sobre seu bem-estar emocional e físico com análises
13       avançadas de dados de saúde.
14     </p>
15     <a href="{% url 'register' %}" class="btn btn-primary btn-lg" role="button">
16       Registre-se agora
17     </a> {# Link para a página de registro, utilizando o sistema de URLs do Django #}
18   </div>
19
20   <div class="row justify-content-center my-5">
21     <div class="col-md-8">
22       <div class="card">
```

```
23     <div class="card-body">
24         <h2 class="card-title">Por que usar o e-Health?</h2>
25         <p class="card-text">
26             O estudo utiliza dados de saúde para oferecer informações valiosas
27             sobre hábitos diários, ajudando a tomar decisões informadas para uma
28             vida mais saudável. Acompanhe e melhore sua qualidade de sono,
29             frequência cardíaca e nível de atividade física conosco.
30         </p>
31         <p class="card-text">
32             Integrando dados pessoais, feedback e informações externas, são
33             propostas recomendações personalizadas, promovendo um estilo de vida
34             equilibrado e bem-estar emocional.
35         </p>
36     </div>
37 </div>
38 </div>
39 </div>
40 </div>
41
42 {% endblock %} {# Encerra o bloco de conteúdo definido anteriormente #}
```