



UNIVERSIDADE FEDERAL DO MARANHÃO

Programa de Pós-Graduação em Ciência da Computação

Joeckson dos Santos Correa

Lhia: Um Agente Conversacional Inteligente para Educação em Aleitamento Materno e Recrutamento de Mães Doadoras

São Luís
2023

Joeckson dos Santos Correa

***Lhia*: Um Agente Conversacional Inteligente para
Educação em Aleitamento Materno e Recrutamento de
Mães Doadoras**

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal do Maranhão, como requisito para a obtenção do título de Mestre em Ciência da Computação.

Universidade Federal do Maranhão – UFMA

Programa de Pós-Graduação em Ciência da Computação

UFMA/IFMA Orientador: Prof. Dr. Ariel Soares Teles

São Luís

2023

Joeckson dos Santos Correa

Lhia: Um Agente Conversacional Inteligente para Educação em Aleitamento Materno e Recrutamento de Mães Doadoras/ Joeckson dos Santos Correa. – São Luís, 2023.

61 f.

Orientador: Prof. Dr. Ariel Soares Teles

Dissertação (Mestrado) – Universidade Federal do Maranhão – UFMA
Programa de Pós-Graduação em Ciência da Computação, 2023.

1. Banco de leite humano. 2. Doação de leite humano. 3. Chatbot. I. Soares Teles, Ariel, orient. II. Título.

CDU XXX

Joeckson dos Santos Correa

Lhia: Um Agente Conversacional Inteligente para Educação em Aleitamento Materno e Recrutamento de Mães Doadoras

Dissertação de Mestrado apresentado ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal do Maranhão, como requisito para obtenção do título de Mestre em Ciência da Computação.

Aprovada em 25 de agosto de 2023

BANCA EXAMINADORA

Prof. Dr. Ariel Soares Teles (Orientador)
(UFMA/IFMA)

Prof. Dr. Luciano Reis Coutinho (Examinador Interno)
(UFMA)

Prof. Dra. Karin Becker (Examinadora Externa)
(UFRGS)

Agradecimentos

Primeiramente, quero agradecer a Deus por ter me dado o privilégio de ter chegado até aqui, sem sua bondade, não seria possível de acontecer.

À minha família: esposa, e pais, pelo incentivo, apoio e compreensão nos tempos bons e difíceis;

A todos os profissionais do Banco de Leite do Hospital Universitário da UFMA, em especial ao Ari Neto, por toda parceria e pelo conhecimento compartilhado.

Ao meu orientador, Ariel Teles, por todo comprometimento e incentivo dado ao longo dos trabalhos feitos.

“Vocês podem pedir qualquer coisa em meu nome, e eu o farei, para que o Filho glorifique o Pai. Sim, peçam qualquer coisa em meu nome, e eu o farei!”
(Bíblia Sagrada, João 14:13,14)

Resumo

O leite materno é a forma mais importante de alimentar e proteger recém-nascidos, já que possui os componentes para garantir a saúde do ser humano. Os Bancos de Leite Humano (BLH) formam uma rede que leva a todo país serviços essenciais para garantir que recém-nascidos e mães possam usufruir dos benefícios do leite materno. Apesar disso, há baixa adesão ao aleitamento materno exclusivo no Brasil, e os estoques de leite humano disponíveis em BLHs usualmente estão abaixo da demanda. O objetivo deste trabalho é codesenvolver um agente conversacional inteligente para a educação em aleitamento materno e captação de doadoras de leite humano para BLHs. Será realizada a metodologia de codesenvolvimento *Conversation-Drive Development* em parceria com profissionais de saúde do BLH do Hospital Universitário da UFMA. O chatbot funcionará como uma tecnologia de comunicação e informação em educação em aleitamento materno para mães. Espera-se que a percepção, o conhecimento e a atitude materna sejam melhorados, e assim a taxa de prevalência de aleitamento materno exclusivo aumente, além do aumento no número de doadoras.

Palavras-chave: Leite humano, Aleitamento materno exclusivo, Chatbot, Doação de leite humano, Processamento de Linguagem Natural

Abstract

Breast milk is the most important way to feed and protect newborns, as it has the components to ensure human health. The Human Milk Banks (HMB) form a network that takes essential services to ensure that newborns and mothers can enjoy the benefits of breast milk. Despite this, there is low adherence to exclusive breastfeeding in Brazil, and human milk stocks available in HMBs are usually below demand. The objective of this work is to co-develop a smart conversational agent for breastfeeding education and human milk donor recruitment for HMBs. The co-development methodology *Conversation-Drive Development* will be conducted in partnership with health professionals from the HMB of the University Hospital of UFMA. The chatbot will work as a communication and information technology in breastfeeding education for mothers. It is expected that maternal perception, knowledge and attitude will be improved, and thus the prevalence rate of exclusive breastfeeding will increase, in addition to the increase in the number of donors.

Keywords: Human milk, Exclusive breastfeeding, Chatbot, Human milk donation, Natural Language Processing.

Lista de ilustrações

Figura 1 – Arquitetura de um chatbot baseado em <i>Inteligência Artificial (IA)</i> . . .	22
Figura 2 – Linha do tempo do procedimento de co-design.	35
Figura 3 – Arquitetura do chatbot <i>Lhia</i>	37
Figura 4 – Total de participantes em cada rodada do procedimento de co-design. .	42
Figura 5 – Número de interações em cada rodada do procedimento de codesign. .	43
Figura 6 – Resultados de desempenho de cada pipeline para a métrica de acurácia nas rodadas de co-design.	44
Figura 7 – Número de gatilhos de <i>fallback</i> em cada rodada do procedimento de co-design.	44
Figura 8 – Respostas do <i>Lhia</i> em cada rodada do procedimento de co-design. . . .	45
Figura 9 – <i>Net Promoter Score (NPS)</i> resultado nas duas últimas rodadas do procedimento de co-design.	46
Figura 10 – Iniciando uma conversa com <i>Lhia</i>	47
Figura 11 – <i>Lhia</i> orientando o usuário com textos e imagens.	48
Figura 12 – Exemplo do mecanismo de notificação ativa.	49
Figura 13 – Exemplo de uma resposta de <i>fallback</i>	49

Lista de tabelas

Tabela 1 – Rodadas do co-design.	36
Tabela 2 – Pipelines de <i>Processamento de Linguagem Natural</i> (PLN) baseadas em <i>Aprendizado Profundo</i> (AP) avaliadas.	39
Tabela 3 – Média dos índices de confiança para intenções usadas em cada rodada do procedimento de co-design.	42

Lista de Siglas

AIML *Linguagem de Marcação de Inteligência Artificial.*

AM *Aprendizado de Máquina.*

AME *Aleitamento Materno Exclusivo.*

AP *Aprendizado Profundo.*

BERT *Bidirectional Encoder Representations from Transformers.*

BLH *Banco de Leite Humano.*

BR-BLH *Rede Brasileira de Bancos de Leite Humano.*

brWaC *Brazilian Portuguese Web as Corpus.*

CDD *Conversation-Driven Development.*

CLN *Compreensão de Linguagem Natural.*

DIET *Dual Intent and Entity Transformer.*

GLN *Geração de Linguagem Natural.*

HU-UFMA *Hospital Universitário da Universidade Federal do Maranhão.*

IA *Inteligência Artificial.*

LHIA *Leite Humano e Inteligência Artificial.*

LLM *Large Language Model.*

MLG *Modelo de Linguagem Grande.*

NPS *Net Promoter Score.*

OMS *Organização Mundial da Saúde.*

PLN *Processamento de Linguagem Natural.*

PT-BR *Português Brasil.*

QA *Question and Answer.*

REN *Reconhecimento de Entidades Nomeadas.*

RNA *Redes Neurais Artificiais.*

UTIN *Unidade de Terapia Intensiva Neonatal.*

UTIs *Unidades de Terapia Intensiva.*

Sumário

	Lista de tabelas	x
	Lista de Siglas	xi
1	INTRODUÇÃO	15
1.1	Contexto Geral	15
1.2	Caracterização do Problema	16
1.3	Hipótese de Pesquisa	17
1.4	Relevância do Trabalho	18
1.5	Objetivos	18
1.6	Organização do Trabalho	19
2	FUNDAMENTAÇÃO TEÓRICA	20
2.1	A Origem do Termo Chatbot	20
2.2	Arquitetura de Chatbots	21
2.3	Chatbot Baseado em Regras	22
2.4	Chatbot Baseado em IA	23
2.5	Processamento de Linguagem Natural	24
2.5.1	Pré-processamento	24
2.5.2	Reconhecimento de Entidades Nomeadas	25
2.5.3	Compreensão de Linguagem Natural	25
2.6	Aprendizado de Máquina	26
2.6.1	Classificação de Intenções	27
2.6.2	Aprendizado Profundo e Chatbots	27
2.7	O Framework <i>Rasa</i>	28
2.7.1	Média dos Índices de Confiança das Intenções	29
2.7.2	Número de Gatilhos de <i>Fallback</i>	29
2.7.3	Índice de Gatilhos de <i>Fallback</i>	30
2.8	Educação em Aleitamento Materno	30
3	TRABALHOS RELACIONADOS	31
4	METODOLOGIA	34
4.1	Visão Geral	34
4.2	Desenvolvimento baseado em Co-design	34
4.3	Fluxo Conversacional do Chatbot	36
4.3.1	Arquitetura do Chatbot	36

4.4	Habilitando <i>Lhia</i> para Responder Perguntas	37
5	RESULTADOS	41
5.1	Participantes	41
5.2	Indicadores	41
5.3	Evolução dos resultados de desempenho	43
5.4	Melhoria do Fluxo Conversacional	43
5.5	Estudos de Caso	45
6	DISCUSSÃO	50
6.1	Principais Achados	50
6.2	Limitações	51
6.3	Trabalhos Futuros	51
7	CONSIDERAÇÕES FINAIS	53
7.1	Contribuições	53
7.1.1	Científica e Social	53
7.1.2	Tecnológica	54
7.2	Publicações	54
	REFERÊNCIAS	55

1 Introdução

1.1 Contexto Geral

A amamentação é um processo que envolve interação entre mãe e bebê, com implicações no estado nutricional do bebê, sistema imunológico, desenvolvimento cognitivo e emocional, e saúde a longo prazo. Além disso, a amamentação tem implicações positivas para a saúde física e psicológica das mães (VICTORA *et al.*, 2016). A amamentação melhora a sobrevivência, a saúde e o desenvolvimento de todas as crianças (VICTORA *et al.*, 2016), previne o câncer de mama e reduz o sangramento pós-parto em mulheres e contribui para o desenvolvimento do capital humano (ROLLINS *et al.*, 2016).

O *Aleitamento Materno Exclusivo* (AME) consiste em oferecer apenas leite humano ao lactente, sem a introdução de qualquer outro alimento sólido ou líquido (ORGANIZATION", 2009). A *Organização Mundial da Saúde* (OMS) recomenda que o AME seja praticado até o sexto mês de vida da criança, e complementado com outros alimentos até o segundo ano de vida (World Health Organization, 2017). A introdução de outros alimentos na dieta do lactente para complementar o leite humano antes do lactente atingir o sexto mês de vida é definida como desmame precoce (SILVA; BASTOS; PIMENTEL, 2019). Apesar dos benefícios do aleitamento materno para mães e bebês, existe uma baixa adesão ao AME no Brasil (VICTORA *et al.*, 2016).

Fornecer o leite humano doado a recém-nascidos vulneráveis sem acesso ao leite materno, além de salvar vidas diretamente, aumenta a conscientização sobre o valor do aleitamento materno por melhorar as taxas gerais de aleitamento materno na sociedade (DATA, 2014). Esses aumentos nas taxas de amamentação são importantes porque podem prevenir até 12% da mortalidade infantil (DATA, 2014). Quando o leite materno é insuficiente, indisponível ou contraindicado, recomenda-se o uso do leite humano doado como alimento prioritário (ORGANIZATION, 2022). No entanto, apesar dos incentivos por meio de políticas públicas para a doação de leite humano, poucas mães se dispõem a doar o leite.

À medida que a comunidade global de *Banco de Leite Humano* (BLH) se esforçou para reduzir a mortalidade infantil e ajudar os recém-nascidos a desenvolverem-se, o compromisso com o BLH se expandiu rapidamente. Na *Rede Brasileira de Bancos de Leite Humano* (BR-BLH), os BLHs são responsáveis por promover o aleitamento materno e realizar atividades de coleta, processamento e controle de qualidade do leite humano para posterior distribuição a uma *Unidade de Terapia Intensiva Neonatal* (UTIN), a qual é uma área hospitalar responsável por fornecer cuidados médicos intensivos a recém-nascidos

prematturos ou com doenças graves.

As mulheres grávidas e as mães de recém-nascidos interagem com os computadores de maneiras diferentes (TANG *et al.*, 2019a). Existem poucos estudos científicos focados em tecnologias para educação sobre amamentação e doação de leite humano. O desenvolvimento de intervenções via Internet para mães que sejam bem-sucedidas requer um conhecimento íntimo e compreensão de seus comportamentos, sentimentos, problemas que enfrentam e uso da tecnologia (SAFI *et al.*, 2020).

Os agentes conversacionais, também conhecidos como chatbots, são sistemas capazes de conversar com usuários utilizando linguagem natural, simulando, assim, interações com humanos (SAFI *et al.*, 2020). Eles ganharam destaque devido à sua capacidade de fornecer experiências de conversação automatizadas, e são implementados em diversas áreas, como saúde, educação, comércio, indústria e entretenimento (TAJ; JHANJHI, 2022). Para desenvolvê-los, técnicas de IA podem ser usadas para melhorar as interações com os usuários finais e, especialmente para a área da saúde, os chatbots baseados em IA têm sido aplicados no treinamento, educação e prevenção em saúde, e também no auxílio diagnóstico e assistência a idosos (MONTENEGRO; COSTA; RIGHI, 2019). Portanto, os chatbots de saúde surgiram como uma ferramenta promissora e parecem ser uma solução adequada para fornecer intervenções para educação sobre amamentação e recrutamento de doadores de leite humano.

Esse trabalho de pesquisa apresenta o processo de desenvolvimento do *Leite Humano e Inteligência Artificial (LHIA)*, um chatbot focado na educação em amamentação e captação de doadoras de leite humano. O chatbot *Lhia* foi desenvolvido usando uma abordagem de co-design, em que 18 profissionais de saúde experientes contribuíram para o desenvolvimento do fluxo conversacional e produziram dados para treinar pipelines de PLN com base em AP (KHURANA *et al.*, 2023) para classificar textos relacionados à diferentes tipos de problemas enfrentados por mães que amamentam e identificar a intenção das mães que desejam ser doadoras de leite humano.

1.2 Caracterização do Problema

Apesar dos benefícios do aleitamento materno para mães e bebês, há baixa adesão ao AME no Brasil (MONTENEGRO; COSTA; RIGHI, 2019). Mães que precisam retornar ao trabalho, crianças que não querem amamentar, introdução de chupeta e/ou mamadeira, problemas mamários como fissuras e ingurgitação, dor ao sugar, angústia ou ansiedade materna e mitos relacionados à amamentação são alguns fatores associados ao desmame precoce no Brasil (FREIRE *et al.*, 2021).

Diferentes políticas públicas têm sido desenvolvidas ao redor do mundo para incentivar, apoiar e promover o aleitamento materno, tais como: a Declaração de Innocenti (UNI-

CEF, 1990), a Convenção das Nações Unidas sobre os Direitos da Criança (UNICEF *et al.*, 2012), e a Iniciativa Hospital Amigo da Criança Lamounier *et al.* (2019). Embora essas iniciativas tenham sido estabelecidas desde o século passado, em países de baixa e média renda, apenas 45% das crianças são amamentadas exclusivamente no Brasil, sendo um valor abaixo do mínimo sugerido pela OMS, o qual é de 50% (Brasil, Ministério da Saúde., 2015).

O BLH é uma das principais estratégias de saúde pública estabelecidas para combater o desmame precoce e manter os benefícios do aleitamento materno para os indivíduos. No entanto, atualmente na região Nordeste do Brasil, incluindo a região de São Luís, os índices de prevalência de aleitamento materno foi de 38%, que estão abaixo do mínimo recomendado 38% pela OMS, segundo Silva (2021). Além disso, os BLHs da rede global de bancos de leite sofrem permanentemente com os baixos estoques de leite humano para processamento e oferta às UTINs (MENESES; OLIVEIRA; BOCCOLINI, 2017).

A doação de leite materno é fundamental para ampliar as chances de recuperação de recém-nascidos prematuros e/ou de baixo peso que estão internados em *Unidades de Terapia Intensiva* (UTIs) neonatais, além de proporcionar um desenvolvimento saudável. Toda mulher que amamenta é uma possível doadora de leite humano e qualquer quantidade de leite humano doado pode ajudar os bebês internados, que, a depender de seu peso e condições clínicas, podem precisar de apenas 1ml a cada refeição. Apesar disto, os estoques de leite humano disponíveis para o processamento quase sempre estão abaixo da demanda, e a busca por leite humano doado para recém-nascidos de alto risco internados em UTIs neonatais está cada vez maior (NEIA *et al.*, 2021). Portanto, novas estratégias de incentivo à doação de leite humano são necessárias.

A baixa adesão ao AME no Brasil é influenciada por diversos fatores, como retorno ao trabalho e resistência da criança (MONTENEGRO; COSTA; RIGHI, 2019). Apesar de existirem políticas públicas para tratar deste problema, apenas 45% das crianças são amamentadas exclusivamente, abaixo do recomendado. Já os BLH enfrentam a falta de estoques para atender às UTIs neonatais, tornando a doação de leite humano essencial para a recuperação de bebês prematuros. Por este motivo, novas estratégias de incentivo à doação são de extrema importância para suprir essa demanda.

1.3 Hipótese de Pesquisa

As intervenções via Internet para amamentação devem se concentrar em garantir o início precoce da amamentação, amamentação exclusiva e continuada (ROLLINS *et al.*, 2016). Um sistema informatizado, que permita capturar e transmitir informações corretas para a educação em amamentação e incentivo a doação de leite materno, pode beneficiar a saúde da mãe e do bebê, auxiliando os profissionais de saúde (ALMOHANNA; WIN;

MEEDYA, 2020).

Baseados na utilização de chatbots como intervenção via Internet para amamentação, nós temos como hipótese que conseguimos melhorar o chatbot nos aspectos de conhecimento sobre aleitamento materno e doação de leite humano, através da utilização da metodologia de co-design. Dessa forma, ele terá capacidade para distinguir diferentes tipos de problemas enfrentados pelas mães que amamentam, assim como incentivar as mães sobre os benefícios de doação de leite humano.

1.4 Relevância do Trabalho

A notória importância do aleitamento materno depende de um processo que envolve interação profunda entre mãe e filho, com benefícios para ambos, que perduram por toda a vida, impactando diretamente no estado metabólico nutricional, na habilidade de se defender de infecções, na fisiologia e no desenvolvimento cognitivo e emocional (SANTOS *et al.*, 2020). No entanto, diferentes fatores influenciam diretamente no sucesso do AME até os seis meses de vida das crianças, impactando no desmame precoce.

Este trabalho é um estudo inicial, o qual foca no desenvolvimento da solução computacional *Lhia*. O desenvolvimento de um chatbot que ajude, por meio da educação, no incentivo ao AME, pode melhorar as taxas de aleitamento na população. Portanto, este trabalho fornece uma nova perspectiva para melhor traçar estratégias de identificação, acolhimento e tratamento de eventuais problemas específicos que levam ao desmame precoce. Além disso, o chatbot pode melhorar a captação de doadoras de leite humano e, consequentemente, aumentar a quantidade de leite humano oferecida às UTINs, representando uma possível forma de combate à morbimortalidade infantil.

1.5 Objetivos

O objetivo deste trabalho de mestrado foi desenvolver um chatbot inteligente para educação em amamentação e recrutamento de mães doadoras de leite materno.

Consideram-se os seguintes objetivos específicos:

- Criar um conjunto de dados inicial com base em pesquisas feitas com os participantes do estudo e na literatura;
- Implementar e avaliar pipelines de aprendizado profundo para a classificação de intenções relacionadas aos principais problemas enfrentados por mães que amamentam;

- Melhorar o conjunto de dados inicial e pipelines com os dados coletados das interações dos participantes durante o estudo de co-design;
- Implementar um mecanismo de notificação ativa para realizar o recrutamento de mães para doação de leite materno;
- Disponibilizar o chatbot em ambiente de produção para outros estudos.

1.6 Organização do Trabalho

O restante desta dissertação de mestrado está organizado como descrito a seguir.

- O **capítulo 2** apresenta a fundamentação teórica com conteúdos técnicos que servem de base para o entendimento do trabalho de pesquisa;
- O **capítulo 3** descreve e discute os trabalhos relacionados;
- O **capítulo 4** explica a metodologia de co-design utilizada para desenvolvimento da pesquisa, e como o fluxo conversacional foi desenvolvido e melhorado. Ele descreve também como o chatbot *Lhia* foi habilitado para responder a perguntas relacionadas à [AME](#);
- O **capítulo 5** apresenta estudos de casos abordando exemplos de interações dos participantes com o chatbot durante a realização do co-design, e os resultados de diferentes métricas analisadas ao longo do processo de implementação e evolução;
- O **capítulo 6** discute os principais achados no estudo, assim como as lições aprendidas, limitações e trabalhos futuros;
- O **capítulo 7** finaliza a dissertação de mestrado com as considerações finais, as principais contribuições desta pesquisa, e listando as publicações de trabalhos científicos.

2 Fundamentação Teórica

Neste capítulo, é apresentado os conceitos associados aos agentes conversacionais, iniciando pela definição do termo chatbot, arquitetura e suas abordagens. Após, há uma contextualização sobre os conceitos de chatbots, sua arquitetura e abordagens utilizadas. A seguir são apresentados as técnicas de Processamento de Linguagem Natural e Aprendizagem de Máquina, e sua aplicabilidade em chatbots. Também é apresentado o framework *Rasa* e seus indicadores de desempenho. O capítulo termina apresentando os conceitos que abrangem as áreas de aleitamento materno.

2.1 A Origem do Termo Chatbot

O conceito de chatbot, ou robô de conversação, não é novo (WEIZENBAUM, 1966). Nos últimos anos, os chatbots foram aplicados a diversos domínios, tais como saúde, educação, área financeira, varejo, dentre outras (KUSAL *et al.*, 2022). Na década de 1950, Alan Turing publicou o artigo *Computing Machinery and Intelligence* (TURING, 1950), que adquiriu grande notoriedade, em que foi apresentada e discutida a questão “As máquinas seriam capazes de pensar?”. Para responder esse questionamento, Alan Turing desenvolveu um método, chamado Teste de Turing, para identificar se uma máquina é capaz de exibir um comportamento inteligente equivalente ou similar ao de um ser humano. Esse teste impulsionou os primeiros passos para o surgimento dos chatbots. O Teste de Turing definia o computador como inteligente quando ele conseguisse dialogar com uma pessoa por um *chat*, sem que ela percebesse estar conversando com uma máquina.

Os primeiros chatbots foram projetados para imitar o comportamento humano, como a “ELIZA” (WEIZENBAUM, 1966) em 1965, em uma conversa baseada em textos, realizando ações específicas e delimitadas em um escopo controlado. O chatbot ELIZA foi um robô conversacional para simular um assistente virtual, a qual utiliza a reformulação de trechos das frases que são capturados das entradas dos usuários, fazendo parecer que possui um vasto vocabulário. O desenvolvimento desse chatbot foi uma primeira tentativa de criar um software que pudesse passar no Teste de Turing (WEIZENBAUM, 1966).

O PARRY foi construído pelo psiquiatra americano Kenneth Colby em 197 (LEPTOURGOS; CORLETT, 2020). Este chatbot tinha a finalidade de imitar o comportamento de um paciente com esquizofrenia. O PARRY tinha a característica de parecer estar adotando falsas crenças de ser assediado, subjugado, perseguido, acusado, maltratado, injustiçado, atormentado e depreciado. Enquanto ELIZA foi considerada uma simulação de um terapeuta, o PARRY simulava um paciente esquizofrênico. No *script* utilizado pelo PARRY durante o diálogo, foram desenvolvidos diferentes tipos de comportamentos

que simulavam o diálogo de forma mais profunda. As conversas não eram baseadas em perguntas e respostas.

Outro chatbot é a ALICE, um acrônimo que significa *Artificial Linguistic Internet Computer Entity*. A primeira edição de ALICE (ABUSHAWAR; ATWELL, 2015) foi implementada em 1995 e o programa ganhou o “Loebner Prize” nos anos de 2000, 2001 e 2004. ALICE possui uma base de conhecimento constituída por centenas de fatos, citações e ideias de seu criador. Esse chatbot apresenta um vocabulário com mais de 5.000 palavras, sendo programado para dar muitas informações a respeito do serviço que disponibiliza. O projeto ALICE (ABUSHAWAR; ATWELL, 2015) é composto por uma base de conhecimento desenvolvida na linguagem *Linguagem de Marcação de Inteligência Artificial* (AIML) que descreve o comportamento do chatbot, e também por um módulo chamado interpretador, que manipula a base de conhecimento.

2.2 Arquitetura de Chatbots

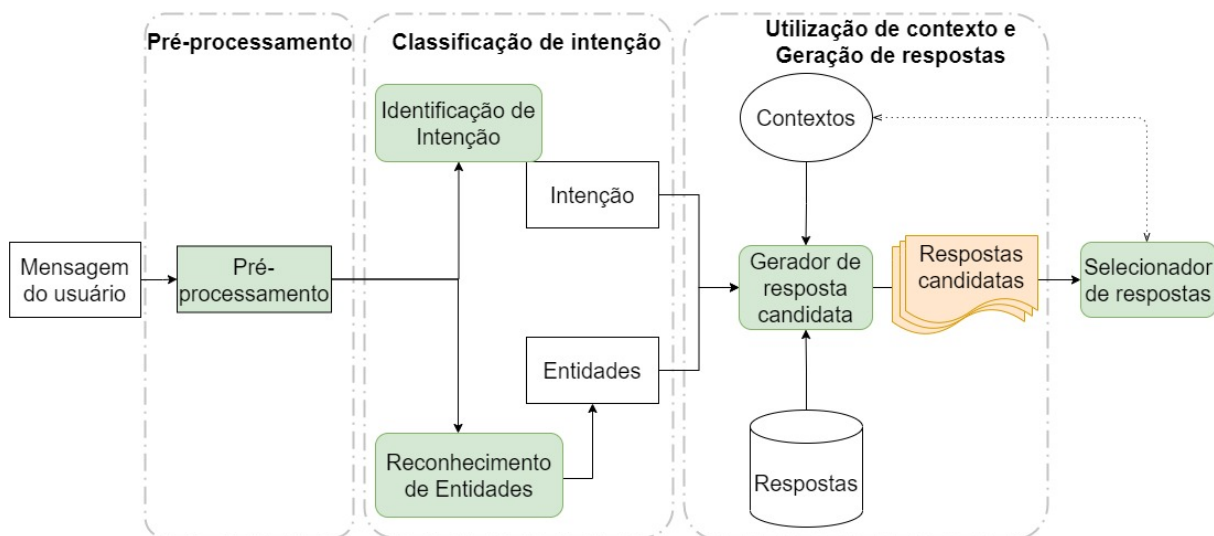
Os chatbots são soluções de software que podem interagir com seres humanos por meio de uma interface de *chat*, podendo ser em forma textual ou por voz (SONG; OH; RICE, 2017). Eles são também conhecidos como *talkbots*, *smartbots*, *bots*, *chatterbots* ou agentes conversacionais. Os chatbots podem se comunicar com o usuário e se comportar como um ser humano. Para isso ocorrer, eles precisam estar conectados a serviços de mensagem (e.g., Facebook Messenger, Telegram, WhatsApp), páginas web ou aplicativos móveis. Os chatbots são classificados em dois tipos: baseados em regras e baseados em IA, os quais são apresentados nas seções a seguir.

Os chatbots baseados em IA são atualmente mais populares, tais como o ChatGPT da OpenIA, o Bard do Google, e o Bing Chat da Microsoft. A arquitetura de um chatbot baseado em IA, conforme mostra a Figura 1, pode ser dividida em três subsistemas: pré-processamento, classificação de intenção, e utilização de contexto e geração de respostas. Inicialmente, o usuário envia uma mensagem de entrada que a entende e produz uma resposta. O pré-processamento executa um conjunto de operações na mensagem para operações adicionais, tais como, *tokenizer*, normalização, eliminação de palavras irrelevantes, identificação das partes do discurso e entidades, *stemming*, *lemmatisation* (KARVE *et al.*, 2018), os quais são explicados nas próximas seções.

A classificação de intenção tem a finalidade de identificar a intenção da mensagem do usuário (ARANHA, 2007). As intenções são rótulos que representam um significado das mensagens de entrada dos usuários. Por exemplo, a mensagem do usuário “Olá, bom dia!” pode ser classificada como “intenção de saudação”.

Os contextos fazem referências às informações fornecidas pelos usuários durante as interações, podendo ser perguntas, respostas e ações anteriores (ARANHA, 2007).

Figura 1 – Arquitetura de um chatbot baseado em IA.



Fonte: adaptado de [Bocklisch et al. \(2017a\)](#).

Os contextos são de extrema relevância, pois ajudam o chatbot a entender melhor as necessidades dos usuários durante as interações. O chatbot também pode utilizar os contextos para entender melhor o que o usuário está procurando, fornecendo, assim, respostas precisas.

Toda resposta está associada a um determinado contexto. Assim, quando uma resposta é gerada, o contexto correspondente é enviado para a pilha. A qualquer momento, a parte superior da pilha indicará o contexto atual da conversa. Esse contexto atual é utilizado como um filtro para selecionar a resposta correspondente à intenção da mensagem do usuário. Caso nenhuma resposta corresponda ao filtro de contexto, a pilha de contexto é exibida para recuperar o contexto anterior. Então as respostas são pesquisadas com o contexto como filtro. Esse processo é repetido até que uma resposta apropriada seja encontrada ([BOCKLISCH et al., 2017a](#)).

2.3 Chatbot Baseado em Regras

A abordagem baseada em regras utiliza o conceito de máquina de estado, a qual consiste em regras que determinam o conjunto de entrada necessário para a transição de um estado para outro ([KAR; HALDAR, 2016a](#)). Isso significa que o chatbot conduz o usuário com perguntas para chegar à resolução correta. As estruturas das perguntas e respostas são pré-definidas para que o chatbot tenha o controle da conversa. Os chatbots baseados em regras podem ser importantes para situações em que o objetivo de sua utilização seja para realizar tarefas específicas, como requisitar uma segunda via de boleto ou acompanhar a situação de uma encomenda. Nesses casos, não é necessário a utilização de abordagens que fazem uso de IA. Os chatbots baseados em regras realizam ações pré-estabelecidas,

deixando claro suas limitações por não terem autonomia suficiente para resolver problemas mais complexos (KAR; HALDAR, 2016b).

Como exemplo, considere um chatbot baseado em regras que seja criado para uma instituição de ensino. Quando um usuário entra em contato com um chatbot, é comum que ele responda com uma mensagem automática, por exemplo, “Em que posso te ajudar?”. Podem ocorrer situações de buscar saber qual é o período de matrícula, documentação para rematrícula ou informação a respeito do contato telefônico da biblioteca. Caso o usuário responda algo diferente do que foi anteriormente sugerido pelo chatbot, tal como “Quero saber minha nota de Matemática”, o chatbot pode não conseguir entender a solicitação e provavelmente repetirá a mensagem automática.

2.4 Chatbot Baseado em IA

Chatbots baseados em IA podem entender linguagem natural e não apenas comandos predefinidos (KUSAL *et al.*, 2022). Além disso, conseguem manter diferentes contextos de conversas e proporcionar ao usuário conversas mais ricas e engajadas (KAPOČIŮTÈ-DZIKIENÈ, 2020). Este tipo de chatbot pode utilizar técnicas de IA para *Compreensão de Linguagem Natural* (CLN) (KHURANA *et al.*, 2023) – em particular, nas tarefas de classificação de intenções e reconhecimento de entidades (BUNK *et al.*, 2020) – e *Geração de Linguagem Natural* (GLN) (ALLOUCH; AZARIA; AZOULAY, 2021). Chatbots com um componente CLN podem analisar a linguagem natural extraíndo conceitos, entidades, emoções, palavras-chave e interpretá-los em uma linguagem de computador (KHURANA *et al.*, 2023). Chatbots com componente GLN, chamados de chatbots generativos, utilizam um *Modelo de Linguagem Grande* (MLG) para gerar respostas de forma fluida e coerente para cada interação feita pelo usuário (ZHAO *et al.*, 2023). Um MLG são modelos de *Aprendizado de Máquina* (AM) que fazem utilização de AP para processar e entender a linguagem natural. Tais modelos são treinados em grandes quantidades de dados de para aprender padrões e relacionamentos entre entidades.

Os chatbots baseados em IA podem entender a linguagem natural e não apenas comandos predefinidos (KUSAL *et al.*, 2022). Além disso, conseguem manter diferentes contextos de conversas e proporcionar ao usuário conversas mais ricas e engajadas (KAPOČIŮTÈ-DZIKIENÈ, 2020). Este tipo de chatbot pode utilizar técnicas de IA para CLN (KHURANA *et al.*, 2023) – em particular, nas tarefas de classificação de intenções e reconhecimento de entidades (BUNK *et al.*, 2020) – e GLN (ALLOUCH; AZARIA; AZOULAY, 2021). Chatbots com um componente GLN podem analisar a linguagem natural extraíndo conceitos, entidades, emoções, palavras-chave e interpretá-los em uma linguagem de computador (KHURANA *et al.*, 2023). Chatbots com componente CLN, chamados de chatbots gerativos (e.g., ChatGPT da OpenIA, Bard do Google, Bing Chat

da Microsoft), utilizam um *Large Language Model (LLM)* para gerar respostas de forma fluida e coerente para cada interação feita pelo usuário (ZHAO *et al.*, 2023)

2.5 Processamento de Linguagem Natural

O PLN surgiu devido à necessidade de compreensão e comunicação automática do ser humano com o computador. O PLN é um mecanismo desenvolvido para extrair informações de textos, facilitar a entrada de dados nos sistemas e a estruturação de dados (SANTOS *et al.*, 2014). O PLN é uma área da Ciência da Computação e da Linguística que estuda os métodos formais para analisar textos e gerar frases em um idioma, através do uso de software (ARANHA, 2007).

Existem quatro etapas no PLN (BULEGON; MORO, 2010): análises morfológica, sintática, semântica e pragmática. A análise morfológica é o estudo de cada palavra presente no texto de forma independente. Essa análise tem a responsabilidade de definir artigos, substantivos, verbos e adjetivos armazenados em um dicionário de palavras com significados semelhantes, em um domínio específico de conhecimento. A análise sintática faz uso do dicionário, primeiramente identificando possíveis relações entre as palavras. Em um segundo momento, ela identifica o sujeito, predicado, complementos nominais e verbais, adjuntos e apostos. Na análise semântica, ocorrem as relações dos termos ambíguos, de sufixos e afixos, ou seja, questões sobre significados associados aos componentes de uma palavra, o sentido real da frase ou palavra. Para a junção e visualização de todas as etapas, a análise pragmática faz a conexão de todo o processo e mostra visualmente o resultado.

2.5.1 Pré-processamento

Para modelar o texto apresentado pelo usuário, possibilitando que a máquina o entenda, é necessário o seu pré-processamento, o qual abstrai e estrutura do texto, deixando apenas o que pode ser considerada uma informação relevante. Esse pré-processamento reduz o vocabulário do texto e torna os dados menos esparsos, uma característica importante para o processamento computacional (ARANHA, 2007).

A **tokenização** (do inglês, *tokenization*) é o início do pré-processamento de texto. Ela ocorre quando uma sequência de caracteres é dividida, delimitada por espaço em branco, vírgula, ponto ou outro delimitador. Cada divisão estabelecida é chamada de *token* (ARANHA, 2007).

O processo de **remoção de stopwords** envolve a eliminação de palavras que não devem ser mantidas no texto. As *stopwords* (MORAIS; AMBRÓSIO, 2007) são conhecidas por serem palavras não importantes na análise do texto. As preposições, pronomes, artigos, advérbios, e outras classes de palavras auxiliares são geralmente classificadas como *stopwords*.

A **normalização morfológica** é uma forma de aumentar a memorização dos diversos significados de um mesmo conceito. Ela visa evitar a repetição das representações de uma palavra a um mesmo conceito (BULEGON; MORO, 2010). Por exemplo, do conceito de “objeto físico que consiste em um número de páginas atadas juntamente” tem-se a palavra “livro”, com as seguintes representações “livro” e “livros”. O processo de normalização propõe que essas duas formas sejam agrupadas em apenas uma, indicando que elas têm o mesmo significado.

Stemming faz parte do processo de normalização, podendo ser classificado por radicalização inflexional ou radicalização para a raiz. A radicalização inflexional tem como característica a utilização das flexões verbais, fazendo truncamentos que tornam as palavras, na maioria das vezes, de difícil compreensão. Por exemplo, “livro”, “livros”, “livreto” são substituídas pelo radical da palavra “livr” (BULEGON; MORO, 2010).

A **lemmatization** faz parte do processo de normalização. Ele tem o objetivo de fazer a substituição das diversas formas de representação da palavra pela forma primitiva. As formas “livro”, “livros” e “livraria” são todas transformadas na sua forma primitiva “livro” (BULEGON; MORO, 2010).

2.5.2 Reconhecimento de Entidades Nomeadas

As entidades são utilizadas para representar pessoas, lugares, instituições, acontecimentos, tempo, dentre outras. Entretanto, para reconhecer essas entidades, é necessário a identificação dos objetos no texto (BULEGON; MORO, 2010). O *Reconhecimento de Entidades Nomeadas* (REN) visa identificar as entidades nomeadas e classificá-las em categorias pré-definidas, tais como Pessoa, Organização, e Local (LIGHT, 1998). Por exemplo:

“Gabriel Barbosa reside em São Luis e estuda na UFMA (Universidade Federal do Maranhão)”

Realizando o REN do exemplo, tem-se: [Gabriel Barbosa], [São Luis], [UFMA] e [Universidade Federal do Maranhão], respectivamente, entidades cujas categorias são. Pessoa, Local, Organização e Organização.

2.5.3 Compreensão de Linguagem Natural

A CLN é uma subárea do PLN que usa a análise sintática e semântica do texto ou da fala para classificar o significado de uma frase. A sintaxe se refere à estrutura gramatical de uma frase, enquanto a semântica diz respeito ao seu significado. Na arquitetura de chatbots, a CLN é um dos principais componentes, tornando o chatbot completo e reduzindo as chances do chatbot não compreender o que o usuário deseja. As principais

funcionalidades da CLN em um chatbot são a classificação de intenções e extração das entidades (BOCKLISCH *et al.*, 2017a).

Como explicado anteriormente, a intenção é uma determinada mensagem do usuário, aquilo que o usuário está tentando transmitir ou realizar durante a conversa. Por exemplo, se um usuário deseja consultar a previsão do tempo, ele pode dizer: “consultar a previsão do tempo”, ou pode simplesmente escrever “previsão do tempo”. Em ambos os casos, o chatbot não vai se concentrar na frase completa. A ideia é que o chatbot possa identificar qual a intenção e, assim, consiga dar uma resposta que faça sentido ao usuário Gupta, Singh e Kumar (2021).

2.6 Aprendizado de Máquina

O AM é uma subárea da IA que permite criar soluções de software com a capacidade de aprender e executar tarefas (HELM *et al.*, 2020). O que torna o programa capaz de aprender por si só, usando um conjunto de dados que passam a representar experiências passadas. O AM é composto por diferentes áreas de pesquisa, tais como IA (RUSSEL; NORVIG *et al.*, 2013), probabilidade e estatística, teoria da complexidade computacional, teoria da informação, filosofia, psicologia, neurobiologia, dentre outras. Tem-se como tarefas do AM a classificação, regressão, agrupamento de dados, previsão de séries temporais, dentre outras (BINI, 2018). A utilização de AM tem crescido na construção de modelos para resolução de problemas em diversos domínios de aplicação, como visão computacional, reconhecimento de fala, e compreensão de texto (RUEDEN *et al.*, 2021).

Existem tarefas descritivas e tarefas preditivas em AM. Nas tarefas descritivas, busca-se o desenvolvimento de algoritmos e modelos (i.e., um algoritmo treinado) que descreve os dados. Entre as tarefas descritivas, uma das principais é o agrupamento de dados (HELM *et al.*, 2020), que busca separar os dados de maneira que dados semelhantes fiquem em um mesmo grupo. Um exemplo da aplicação de agrupamento de dados é o agrupamento de textos. Nesse caso, o algoritmo procura agrupar textos que abordem o mesmo assunto e separar em grupos diferentes os textos que abordam assuntos diferentes.

As tarefas preditivas podem ser divididas em tarefas de classificação e regressão. Nas tarefas de classificação, busca-se atribuir categorias predefinidas a exemplos de entrada. Por exemplo, um banco pode desenvolver um sistema para a classificação de seus clientes em duas categorias para fornecimento de empréstimo: SIM e NÃO. Por meio do histórico de crédito dos clientes, e também de dados como salário e tempo de emprego, o sistema pode aprender a distinguir os clientes para os quais o banco deve (SIM) ou não deve (NÃO) fornecer um empréstimo. Assim, tem-se um sistema de recomendação de crédito, cujas categorias a serem preditas para um novo cliente são SIM e NÃO (atributo de saída). Nas tarefas de regressão, objetiva-se prever o valor de uma variável numérica (atributo de

saída, i.e., variável dependente), dadas outras variáveis (atributos de entrada, i.e., variáveis independentes). Assim, em vez de encontrar uma classe associada, como na classificação, deve-se encontrar uma função que mapeie um exemplo para um número.

2.6.1 Classificação de Intenções

A classificação de intenções é a categorização de forma automática de dados de texto com base nos objetivos do usuário (SASAKI *et al.*, 2008). Um classificador de intenções analisa os textos e os categoriza em intenções. Isso permite entender as intenções por trás das mensagens do usuário, automatizar processos e obter informações úteis. Toda interação com o usuário tem um propósito, objetivo ou intenção (ALI, 2020).

A classificação de intenção pode usar AM e PLN para fazer a associação de palavras ou expressões de forma automática a uma determinada intenção do usuário. Por exemplo, um modelo de AM pode realizar um agendamento de uma consulta médica através das sentenças, “quero consultar” ou “consulta médica” que estão associadas à intenção “consultas paciente”. Para isso ocorrer, o classificador de intenções precisa ser treinado com dados de exemplos, conhecidos como dados de treinamento ou frases de treinamento. Por exemplo, se o chatbot for destinado a realizar tarefas de vendas de lanches, deve-se escolher sentenças como: “quero comprar lanche” ou “quero lanche”. Após a definição dos rótulos das classes, pode ser dado início ao processo de treinamento do classificador de intenções, repassando os exemplos de textos ou frases de treinamento para cada sentença. Por exemplo, “Quero comprar um suco de goiaba”.

2.6.2 Aprendizado Profundo e Chatbots

Aprendizado Profundo AP é uma sub-área de AM (BINI, 2018). Mais especificamente, trata de *Redes Neurais Artificiais* (RNA), uma área que busca simular computacionalmente o cérebro enquanto máquina de aprendizado (PACHECO; PEREIRA, 2018). Atualmente é uma área de pesquisa extremamente ativa, que pode ser aplicada em diversas áreas, tais como reconhecimento de fala, visão computacional, e também em chatbots. Existem chatbots baseados em AP que podem ser divididos em duas categorias: baseados no modelo de recuperação, e generativa (CSAKY, 2019).

Recentemente Kung *et al.* (2023) apontou que chatbots generativos, como ChatGPT, Bard e Bing Chat, podem ter o potencial de auxiliar na educação médica e, potencialmente, na tomada de decisões clínicas. A *Lhia* se diferencia dos chatbots generativos atuais por ser desenvolvido em um processo de co-design com a participação de profissionais de saúde especializados em amamentação, disponibilizando conteúdo técnico validado por eles. *Lhia* usa um pipeline de PLN baseado em AP para abordar problemas específicos de amamentação e, por meio da educação, ensinar o manejo correto de tais problemas.

Também identifica a intenção das mães que desejam ser doadoras de leite humano e incentiva as mães a doarem leite humano por meio de notificações ativas. Além disso, a *Lhia* se diferencia dos chatbots generativos por utilizar conteúdo multimídia, incluindo não apenas textos, mas também emojis e imagens ilustrativas.

2.7 O Framework *Rasa*

Segundo [Bocklisch et al. \(2017b\)](#), o *Rasa* é um framework de código aberto projetado para ser de fácil utilização na construção de sistemas conversacionais. Ele é estruturado em dois principais componentes: Compreensão de Linguagem Natural (*Rasa NLU*) e o Gerenciamento de Diálogo (*Rasa Core*). Essa modularidade favorece a integração com outros sistemas, permitindo, por exemplo, que o *Rasa Core* atue como gerenciador de diálogo em conjunto com serviços de CLN distintos do *Rasa NLU*. Além disso, ambos os componentes podem oferecer APIs para facilitar sua utilização em projetos que utilizem diversas linguagens de programação.

O *Rasa NLU* ([AGARWALA et al., 2019](#)) é responsável pelo PLN, interpretando a entrada do usuário, categorizando a entrada em entidade e classificando na intenção desejada. A plataforma provê flexibilidade para utilizar diferentes bibliotecas ou frameworks de linguagem natural, tais como, spaCy, NLTK, CoreNLP, e BERT.

O *Rasa*, por ser um framework de código aberto, fornece pipelines de PLN e com várias maneiras de configurá-las. Isso inclui a flexibilidade de adicionar ou remover etapas de processamento conforme necessário. Os pipelines determinam a ordem e as ações a serem executadas para garantir que o chatbot compreenda corretamente as entradas dos usuários ([AGARWALA et al., 2019](#)).

O *Rasa Core* ([BRAUN et al., 2017](#)) é responsável por receber todas as intenções e entidades do usuário, e direciona uma ação a ser realizada por meio de um modelo de AM. O *Rasa Core* atribui uma pontuação (usualmente uma probabilidade) a todas as ações possíveis e executa aquela com maior valor.

O *framework Rasa*, fornece indicadores para analisar o desempenho do chatbot ao longo do tempo, fazendo isso podemos obter melhores resultados e entender melhor as necessidades do usuário. Os indicadores fornecidos pelo *rasa*, podem ser classificados em análise do usuário, análise de uso, análise de conversa e *business analytics*. Todos os indicadores apresentados neste estudo foram utilizados para um obter um melhor entendimento dos estudos realizados.

O *framework Rasa* oferece indicadores que permitem analisar o desempenho do chatbot ao longo do tempo. Com isso, ele aumenta as possibilidades de alcançar bons resultados e um melhor entendimento das necessidades dos usuários. Esses indicadores

fornecidos pelo *Rasa* podem ser categorizados em grupos, tais como: análise do usuário, análise de uso, análise de conversa e *business analytics*. Os indicadores foram aplicados neste trabalho, tiveram o intuito de obter uma melhor compreensão dos resultados dos estudos realizados.

2.7.1 Média dos Índices de Confiança das Intenções

O índice de confiança calculado pelo *Rasa*, é a probabilidade associada a uma determinada intenção classificada a partir da mensagem de entrada do usuário. Ou seja, quando o usuário envia uma mensagem para o chatbot ela é processada pelo *Rasa* para poder identificar qual será a intenção que representa a intenção do usuário. Dessa forma, o índice de confiança é uma pontuação que varia entre 0 e 1, em que 0 indica que não houve nenhuma confiança identificação da intenção, e 1 indica a maior confiança na identificação da intenção.

Por exemplo, ao receber e processar uma mensagem de entrada do usuário, o chatbot pode classificar que a intenção principal é “agendar consulta médica” tendo um índice de confiança de 0,75. Isso significa que o chatbot está 75% confiante de que a intenção do usuário é agendar uma consulta médica com base no processamento que o chatbot realizou.

O indicador de Média do Índice de Confiança das Intenções é calculado a partir da soma de todos os índices de confiança coletados, dividida pelo número total das classificações de intenções.

2.7.2 Número de Gatilhos de *Fallback*

No *Rasa*, uma *fallback* é quando o chatbot não consegue identificar com confiança a intenção pretendida com relação à mensagem de entrada do usuário.

O gatilho de *fallback* é um mecanismo responsável por lidar com cenários onde o chatbot não consegue responder adequadamente a respectiva mensagem de entrada do usuário. Sempre que o usuário envia uma mensagem para o chatbot, o *Rasa* processa e classifica a intenção associada a essa mensagem. Se a confiança prevista for menor do que uma pontuação pré-definida nas configurações do *Rasa* (0.4), a confiança é considerada baixa, dessa forma o gatilho de *fallback* é ativado.

Este indicador equivale à quantidade de ocorrências de gatilhos de *fallback* para cada mensagem enviada do usuário para o chatbot.

2.7.3 Índice de Gatilhos de *Fallback*

Tendo a quantidade de ocorrência dos gatilhos de *fallback*, é possível extrair o indicador de índice de gatilho de *fallback*. Ele equivale à porcentagem das mensagens que o chatbot não conseguiu entender. O índice de *fallback* é obtido usando a Equação 2.1. Quanto menor o percentual, menores são as chances do chatbot não entender a mensagem do usuário quando o chatbot estiver em produção.

$$\text{Índice de fallback} = \frac{\text{numero de gatilho de fallback}}{\text{número total de interações}} \quad (2.1)$$

2.8 Educação em Aleitamento Materno

A educação em amamentação visa aumentar o conhecimento e as habilidades das mães em amamentação, ajudá-las a ver a amamentação como normal e ajudá-las a desenvolver atitudes positivas em relação à amamentação (CDC, 2008). Embora o público sejam geralmente mulheres grávidas ou amamentando, pode incluir também pais (RAEISI *et al.*, 2014) e outros que apoiam a mãe que está amamentando (NEGIN *et al.*, 2016). A educação em aleitamento materno pode ocorrer em ambiente hospitalar ou clínico, bem como em bibliotecas, centros comunitários, igrejas, escolas, locais de trabalho e outros locais, desde que orientado com experiência e conhecimentos específicos no manejo da amamentação (CDC, 2008).

Diferentes estratégias de apoio à amamentação podem ser utilizadas, desde que levem em consideração as necessidades individuais de cada mãe durante o processo de amamentação, buscando melhorar seus sentimentos, capacidade de poder e sua eficácia na amamentação (DEMIRTAS, 2012). A educação em amamentação é uma estratégia eficaz para promover o aleitamento materno exclusivo (KE; OUYANG; REDDING, 2018). O apoio domiciliar pós-natal oferecido por agentes comunitários de saúde também aumenta a duração e o conhecimento da amamentação (SITRIN *et al.*, 2015).

A educação por meio de mensagens de texto móveis ou da Internet também tem sido considerada uma ferramenta eficaz para promover o AME (GIGLIA *et al.*, 2015). Juntamente com os métodos de apoio mais tradicionais, a Internet oferece outro método possível para promover resultados positivos da amamentação a longo prazo (Giglia *et al.* (2015).

3 Trabalhos Relacionados

Estudos têm relatado resultados positivos relacionados à usabilidade e eficácia de chatbots na área da saúde, mas as evidências ainda não são fortes (MILNE-IVES *et al.*, 2020). Um número crescente de chatbots para saúde foram desenvolvidos e estudados, incluindo aqueles voltados para a educação em saúde (MONTENEGRO; COSTA; RIGHI, 2019; XU *et al.*, 2021). Além disso, abordagens baseadas em aprendizado de máquina/profunda foram usadas com frequência para desenvolver sistemas de chatbot no domínio da saúde (SAFI *et al.*, 2020).

As intervenções via Internet têm sido eficazes para apoiar a amamentação (LAU *et al.*, 2016; MCARTHUR; OTTOSEN; PICARELLA, 2018), principalmente para fornecer educação sobre amamentação por meio de sistemas persuasivos projetados para incentivar as mães a amamentar (TANG *et al.*, 2019a) ou fornecer conselhos durante todo o processo de amamentação (GEOGHEGAN-MORPHET *et al.*, 2014). O fornecimento remoto de apoio e educação em amamentação tem demonstrado ser eficaz para melhorar os resultados da amamentação, principalmente em ambientes onde o apoio de pessoal qualificado não é viável ou prontamente disponível (GAVINE *et al.*, 2022). Ao considerar essa área de aplicação dos chatbots como ferramenta de intervenção via Internet, a análise dos trabalhos relacionados será direcionada àqueles estudos focados no desenvolvimento e experimentação de chatbots no contexto de aleitamento materno.

Uma primeira iniciativa de chatbot para suporte educacional em amamentação foi Tanya (EDWARDS *et al.*, 2013). Ela era uma personagem feminina multirracial animada por computador que era exibida na tela do computador. O estudo piloto com 15 mães no período perinatal demonstrou que o chatbot pode servir para melhorar as taxas de amamentação exclusiva, principalmente quando não há suporte adequado de profissionais de saúde (EDWARDS *et al.*, 2013). Ao avaliar a capacidade de um chatbot de manter longitudinalmente a continuidade dos cuidados no pós-natal, Zhang *et al.* (2014) observaram que o uso doméstico de Tanya pode ajudar as mães com a estabilidade, confiabilidade e conforto durante a amamentação.

YADAV *et al.* (2019) tiveram como objetivo entender o potencial dos chatbots para educação sobre amamentação na Índia. Eles conduziram um experimento do Mágico de Oz (ou seja, um humano emulando as funcionalidades de um chatbot) que fez os participantes acreditarem estarem conversando com um chatbot real. Os resultados demonstraram que a maioria das perguntas relacionadas à amamentação pode ser respondida por um chatbot.

Wong *et al.* (2021) desenvolveram um estudo visando entender a usabilidade e viabilidade em utilizar chatbots para coletar dados de conversas em tempo real sobre

estresse, sono e alimentação infantil de pais com filhos recém-nascidos. O estudo também aborda duas análises. A primeira faz referência sobre a experiência dos pais com bebês nascidos a termo, ou seja, bebês que nascem após completarem o período de gestação adequado para seu desenvolvimento completo antes do nascimento. Segunda, analisa a experiência de pais com bebês prematuros. Foram desenvolvidos três versões de chatbot para capturar interações com os pais via dispositivos móveis. Houve um total de 45 participantes, dos quais 26 completaram o estudo. Os principais achados do experimento foram: o estudo compara pais com bebês prematuros e a termo em relação ao estresse emocional, sono e problemas de alimentação. Pais de bebês prematuros relataram mais estresse e problemas de alimentação, mas ambos os grupos tiveram uma qualidade de sono satisfatória. As interações no grupo prematuro foram mais centradas em estresse, desconforto e cansaço, enquanto interações positivas foram mais comuns no grupo a termo. Discussões sobre alimentação também destacaram sua relação com o sono dos pais. Em geral, os pais que concluíram o estudo deram feedback positivo sobre sua experiência com o chatbot como uma ferramenta para expressar seus pensamentos e preocupações.

Chung, Cho e Park (2021) tiveram como objetivo desenvolver e avaliar um chatbot para área da saúde baseado em *Question and Answer (QA)*, o *Dr. Joy*. O chatbot foi criado para o cuidado obstétrico e saúde mental de mulheres perinatais e seus parceiros, com a utilização de técnicas de mineração de texto. O estudo teve como participantes um total de treze mulheres e dois homens, e durante um período de sete dias os participantes interagiram com o *Dr. Joy*, dando feedback positivo ou negativo. Um questionário foi aplicado após a conclusão do experimento para avaliar os benefícios e riscos encontrados, assim como identificar se os participantes tinham intenção de buscar e compartilhar informações de saúde com o chatbot, e também os pontos fortes e fracos dos chatbots durante as interações. Os resultados indicaram que a facilidade de aprendizado não estava significativamente associada à utilidade, usabilidade ou satisfação. Os benefícios identificados tiveram associações positivas com a intenção dos participantes em buscar e compartilhar informações de saúde no chatbot, enquanto os riscos percebidos não tiveram associações negativas com essas intenções. O estudo mostrou o potencial do uso do chatbot *Dr. Joy* para o cuidado obstétrico e de saúde mental, mas havendo a necessidade de atualizar periodicamente suas respostas para satisfazer as demandas dos usuários.

No Brasil, um primeiro esforço relacionado foi realizado por Barreto *et al.* (2021), ao desenvolverem e avaliar o GISSA. Este chatbot se preocupa com a saúde materno-infantil no Brasil e possui um módulo desenvolvido para mães/cuidadoras de crianças menores de dois anos. O módulo fornece informações relacionadas à amamentação, introdução alimentar, imunização e marcos de crescimento e desenvolvimento. Uma avaliação experimental com 142 púperas utilizando o chatbot GISSA demonstrou bons resultados em relação ao seu uso pelas participantes com simplicidade, qualidade de informação, clareza de conteúdo, utilidade e satisfação.

Embora os chatbots para cuidados de saúde estejam evoluindo, até onde pesquisamos no contexto deste trabalho de mestrado, pouco foi feito especificamente usando chatbots como intervenção na educação sobre amamentação e recrutamento de mães doadoras (TANG *et al.*, 2019b). Diferente das propostas anteriores, o *Lhia* é uma ferramenta pensada para oferecer uma forma inovadora de apoiar as mães que amamentam, por meio da educação e, ainda, recrutar mães para doarem leite humano ao BLH. É proposta para a língua portuguesa brasileira (PT-BR), a língua oficial e mais falada do Brasil, voltada para aspectos da cultura da amamentação no contexto brasileiro. O *Lhia* foi desenvolvido a partir de um conhecimento técnico utilizando uma abordagem de co-design, em que profissionais de saúde experientes colaboraram para a construção do fluxo conversacional. Além disso, um pipeline de PLN baseado em AP foi implantado para permitir que o chatbot responda a perguntas relacionadas à amamentação.

4 Metodologia

Neste capítulo, apresentamos a metodologia utilizada durante o desenvolvimento do chatbot, iniciando-se por uma visão geral da proposta do chatbot, em seguida explica-se sobre o desenvolvimento baseado em co-design, assim como sua aplicabilidade no estudo. Na sequência, é explicado como o fluxo conversacional foi criado e seu embasamento, seguindo pela apresentação da arquitetura do chatbot utilizada. O capítulo termina com a apresentação de como o chatbot foi habilitado para responder perguntas.

4.1 Visão Geral

O chatbot *Lhia* é proposto como um agente virtual de amamentação que utiliza conversas baseadas em mensagens de texto e imagens ilustrativas via Telegram e WhatsApp. Ele foi desenvolvido em parceria com o BLH do *Hospital Universitário da Universidade Federal do Maranhão (HU-UFMA)*, centro voltado à promoção, proteção e apoio ao aleitamento materno exclusivo, que atua há mais de 20 anos em uma maternidade. O chatbot *Lhia* permite a identificação de diferentes tipos de problemas enfrentados pelas mães que amamentam. Ele é capaz de identificar quando a mãe apresenta algum problema que pode levar ao desmame precoce e, assim, intervir, orientando-a corretamente ou indicando o cuidado profissional adequado para garantir o sucesso da amamentação. Além disso, o chatbot *Lhia* incentiva a doação de leite humano por meio de um mecanismo de notificação ativo, ou seja, inicia de forma autônoma conversas destinadas ao recrutamento de mães.

4.2 Desenvolvimento baseado em Co-design

Slattery, Saeri e Bragge (2020) abordam que o co-design na pesquisa implica na participação ativa dos usuários finais em todas as fases da investigação. Os autores definiram co-design de pesquisa como o envolvimento significativo dos usuários na fase de planejamento do estudo de um projeto de pesquisa em saúde.

Neste estudo, utilizamos o co-design para envolver os usuários finais desde o início do desenvolvimento até a versão final do chatbot. Os usuários desempenharam um papel fundamental, colaborando com os desenvolvedores ao fornecer *insights* e *feedback*. É importante destacar que o co-design em um projeto de desenvolvimento de chatbot tem grandes possibilidades de assegurar que a versão final atenda às reais expectativas dos usuários, inclusive podendo resultar em um chatbot mais intuitivo e alinhado com a experiência desejada.

Este estudo envolveu dezoito ($n=18$) profissionais de saúde que atuam no HU-UFMA, especificamente com aleitamento materno. Foram incluídos os profissionais que trabalhavam no ambulatório especializado em amamentação há pelo menos 2 anos e excluídos aqueles que atuavam em diferentes setores do ambulatório de atenção às mães. O estudo foi aprovado pela comissão científica e conselho de ética institucional do HU-UFMA (nº 5.770.812).

Uma abordagem de co-design (BIRD *et al.*, 2021) foi usada para desenvolver o chatbot proposto, que consistiu em ouvir os profissionais de saúde e usar seus requisitos e *insights* no projeto e melhoria do fluxo conversacional. Além disso, como os participantes interagiram com o chatbot continuamente em cada nova versão lançada, eles produziram textos (ou seja, conversas simulando mães) usados para treinar pipelines de PLN baseados em AP para construir modelos de classificação de intenção. A Figura 2 apresenta a linha do tempo com o passo a passo do procedimento de co-design, descrito a seguir.




Figura 2 – Linha do tempo do procedimento de co-design.

1. **Desenvolvimento:** Nesta fase, a primeira versão da *Lhia* foi desenvolvida e disponibilizada para ser utilizada pelos participantes;
- 2, 3. **Interação e Resultados Parciais/Refinamento:** esta etapa ocorreu em quatro rodadas, conforme explicado na Tabela 1, as três primeiras duraram de 7 dias e a última 120 minutos durante uma oficina presencial de discussão. Durante este processo interativo, realizamos várias sessões de treinamento com diferentes pipelines PLN baseados em AP para identificar aquele com o melhor resultado de precisão para ser implantado no *Lhia*. Além disso, esse processo de desenvolvimento iterativo nos permitiu melhorar o fluxo da conversa com base nas sugestões dos participantes. O fluxo foi aprimorado das seguintes maneiras: conteúdo aprimorado com adição de figuras e melhores explicações, ajuste do vocabulário utilizado e aumento do número de respostas do chatbot (ou seja, enunciados). Durante cada rodada, coletamos o número de gatilhos de *fallback* – ou seja, um *fallback* é acionado por uma baixa pontuação de confiança ($\leq 0,4$; o chatbot não é capaz de classificar uma intenção do usuário) na classificação da intenção do usuário – a confiança pontua no usuário a classificação da intenção, o número de interações do usuário, o número de participantes

interagindo com o chatbot e, nas duas últimas rodadas, o *Net Promoter Score* (NPS) (KROL *et al.*, 2015) em uma escala *Likert* de 3 respostas.

4. **Produção:** finalmente, após o processo interativo, *Lhia* chegou a uma versão para ser colocada em produção.

Tabela 1 – Rodadas do co-design.

Rodada	Canal	Intenções	Duração	Melhorias do fluxo
1	Telegram	4	7 dias	Fluidez e engajamento
2	Telegram	6	7 dias	Conteúdo
3	WhatsApp	6	7 dias	Melhorias específicas com base nas sugestões dos participantes
4	WhatsApp	6	2 horas	N/A

4.3 Fluxo Conversacional do Chatbot

O fluxo conversacional do chatbot *Lhia* baseou-se inicialmente no livro de atenção básica (Saúde da Criança - Aleitamento Materno e Alimentação Complementar) do Ministério da Saúde (HEALTH", 2015). Além disso, consideramos o capítulo modelo para livros didáticos para estudantes de medicina e profissionais de saúde aliados - Alimentação de Bebês e Crianças Pequenas (ORGANIZATION", 2009) para desenvolver o fluxo de conversação.

4.3.1 Arquitetura do Chatbot

A Figura 3 mostra a arquitetura do chatbot *Lhia*, que foi construída na framework *Rasa*. A arquitetura possui 5 componentes, conforme segue:

- ***Lhia-Core*** é o componente responsável por reconhecer as entradas do usuário. Ele usa um pipeline de PLN baseado em AP, classificando intenções e fornecendo respostas;
- ***Lhia-Action*** processa requisições enviadas do componente *Lhia-Core*. Por exemplo, durante uma conversa, o *Lhia-Core* pode enviar uma requisição para identificar se o usuário está interagindo pela primeira vez (ou seja, verificar se existe um histórico de conversas anteriores). O ***Lhia-Action*** também pode agendar tarefas no componente *Lhia-Events*, como mensagens de notificação a serem enviadas ao usuário;
- ***Lhia-Events*** é um broker de *publisher/subscriber*, no qual *Lhia-Action* atua como produtor e *Lhia-Task* como consumidor;

- **Lhia-Task** é um componente para agendamento de tarefas e envio de notificações. Ele consome tarefas do *Lhia-Events*, que são agendadas de acordo com parâmetros de tempo. Após o processamento, notificações de incentivo à doação e orientações sobre aleitamento materno exclusivo são enviadas para o componente *Lhia-Core*;
- **DB Atlas** é um componente usado para armazenar todas as interações entre os usuários e o chatbot;
- **Conectores** são componentes que fornecem canais de comunicação entre os usuários e o chatbot. A arquitetura do *Lhia* possui conectores para o WhatsApp e o Telegram.

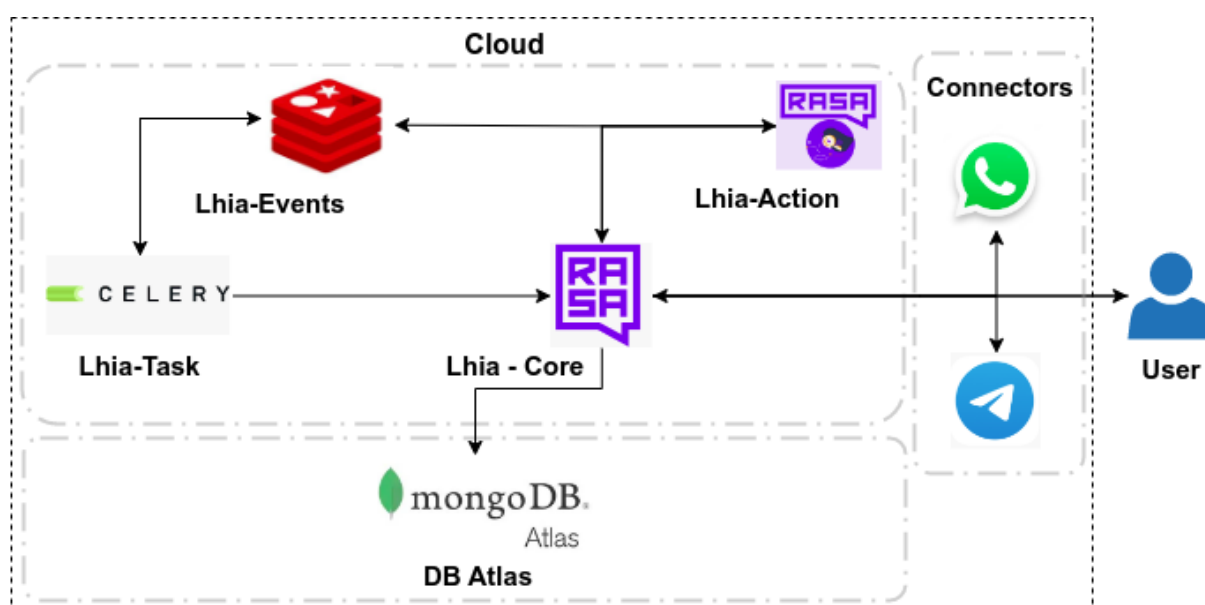


Figura 3 – Arquitetura do chatbot *Lhia*.

4.4 Habilitando *Lhia* para Responder Perguntas

Cada interação do usuário tem um propósito, chamado de intenção do usuário (AREVALILLO-HERRÁEZ; ARNAU-GONZÁLEZ; RAMZAN, 2022). A classificação de intenção é a categorização automática de dados de texto com base nos objetivos do usuário. Um classificador de intenção analisa os textos e os categoriza em intenções. A classificação de intenção pode usar pipelines de PLN baseados em AP para associar automaticamente palavras ou frases com uma determinada intenção do usuário, ou seja, CLN (KHURANA *et al.*, 2023).

O *Rasa* precisa compreender as mensagens de entrada do usuário, e esse entendimento das mensagens ocorre por meio de pipelines responsáveis pelo processamento sequencial das mensagens do usuário. Um pipeline tem componentes que lidam com diferentes tarefas, como gerenciamento de entidade, classificação de intenção e seleção

de resposta. Na plataforma *Rasa*, os pipelines são configurados no arquivo *config.yml* usando 5 componentes (Rasa, 2021): modelos de linguagem, *tokenizadores*, *textitfeaturizers*, classificadores de intenção e seletor de resposta.

Na primeira versão do chatbot (ou seja, antes de iniciar o procedimento de co-design), frases relacionadas a cada problema enfrentado pelas mães que amamentam (ou seja, aulas em um problema de classificação multiclasse de aprendizado de máquina) foram coletadas por meio de entrevistas com os 18 profissionais de saúde, e então usado para realizar o treinamento dos pipelines antes da primeira rodada de co-design. Durante todo o processo de co-design, o conjunto de dados foi aprimorado a partir da coleta de dados durante as interações do usuário. *Rasa* usa os três arquivos a seguir para realizar o treinamento do pipeline:

- ***nlu.yml*** tem todos os problemas enfrentados pela mãe categorizados como intenções, e cada intenção contém amostras de frases;
- ***domain.yml*** contém as respostas e ações para cada intenção correspondente no arquivo *nlu.yml*;
- ***stories.yml*** contém o fluxo conversacional baseado em histórias, em que cada história contém um ou mais intenções.

Conforme descrito na Tabela 2, definimos 5 pipelines *Rasa* diferentes para realizar experimentos e encontrar aquele com o melhor desempenho, considerando a precisão como métrica (Equação 4.1), baseada na matriz de confusão. O conjunto de dados foi dividido em 80% para treinamento/validação e 20% para teste. Em cada rodada de co-design, implementamos no chatbot a pipeline que alcançou melhor desempenho na sessão de treinamento, que por sua vez, foi treinado usando os dados adicionados da rodada anterior. No entanto, após todas as rodadas do procedimento de co-design e identificado o pipeline com melhor desempenho, treinamos ele com 100% dos dados, e o implantamos na versão de produção do chatbot *Lhia*.

$$Acurácia = \frac{\textit{classificações corretas}}{\textit{todas classificações}} \quad (4.1)$$

Cada componente presente nos pipelines descritos na Tabela 2 é descrito abaixo.

- ***WhitespaceTokenizer*** é responsável pela etapa inicial de pré-processamento, na qual os textos são divididos em unidades menores (palavras ou caracteres), ou seja, tokens únicos. Essa separação ocorre a partir dos espaços em branco entre cada palavra ou caractere, com mensagens do usuário como entrada e uma lista de tokens exclusivos como saída;

Tabela 2 – Pipelines de PLN baseadas em AP avaliadas.

Pipeline	Descrição
P1	WhitespaceTokenizer, LexicalSyntacticFeaturizer, CountVectorFeaturizer, DIETClassifier
P2	WhitespaceTokenizer, RegexFeaturizer, LexicalSyntacticFeaturizer, CountVectorFeaturizer, DIETClassifier
P3	WhitespaceTokenizer, BERTimbau-base, LexicalSyntacticFeaturizer, CountVectorFeaturizer, DIETClassifier
P4	WhitespaceTokenizer, BERTimbau-large, LexicalSyntacticFeaturizer, CountVectorFeaturizer, DIETClassifier, FallbackClassifier
P5	WhitespaceTokenizer, BERT-multilingual, LexicalSyntacticFeaturizer, CountVectorFeaturizer, DIETClassifier

- ***LexicalSyntacticFeaturizer*** é um componente responsável por extrair recursos como palavras-chave, sequências de palavras relevantes, categorias gramaticais, *n-gramas* e propriedades lexicais. Além disso, usa técnicas de processamento de texto para analisar a estrutura gramatical e as propriedades lexicais das sentenças de entrada;
- ***CountVectorFeaturizer*** identifica a frequência das palavras, sem considerar o seu significado contextual ou semântico nas frases;
- ***DIETClassifier*** é o componente com o *Dual Intent and Entity Transformer (DIET)* (BUNK *et al.*, 2020), que é uma arquitetura multitarefa para classificação de intenções e reconhecimento de entidades. Ele gera as pontuações de confiança para cada intenção associada à mensagem do usuário;
- ***FallbackClassifier*** é o componente responsável por lidar com as ocasiões em que o chatbot não pode classificar uma intenção. Ele fornece uma resposta padrão, quando um gatilho de *fallback* é acionado (ou seja, a resposta de *fallback*).

Experimentamos pipelines com o modelo pré-treinado **DIET** atuando como classificador, que já demonstrou alto desempenho (BUNK *et al.*, 2020). Também experimentamos três *embeddings* de palavras diferentes do *Bidirectional Encoder Representations from Transformers (BERT)* para a língua portuguesa (WOLF *et al.*, 2020): BERT Multilíngue (base) (DEVLIN *et al.*, 2019; DEVLIN *et al.*,) e BERTimbau (SOUZA; NOGUEIRA; LOTUFO, 2020; Fábio Souza and Rodrigo Nogueira and Roberto Lotufo, a; Fábio Souza and Rodrigo Nogueira and Roberto Lotufo, b) (base e grande). BERTimbau é uma versão especializada do **BERT** para *Português Brasil (PT-BR)*, que foi treinada usando dados da

Brazilian Portuguese Web as Corpus (brWaC) (FILHO *et al.*, 2018; Neurocognition and Natural Language Processing Research Lab,), um grande e diversificado corpus de páginas da web em PT-BR. Dados textuais foram enviados como entrada para treinamento de pipelines de PLN baseados em AP usando a plataforma *Rasa*.

5 Resultados

Este capítulo apresenta os resultados obtidos durante todo o estudo, iniciando-se pela apresentação dos participantes envolvidos no estudo. Em seguida, são apresentados os indicadores, em que é possível observar a evolução do chatbot, assim como do seu fluxo conversacional. O capítulo finaliza com uma descrição de estudos de casos.

5.1 Participantes

No total, foram 18 indivíduos (16 mulheres) que participaram deste procedimento de co-design. Todos os integrantes eram brasileiros, com idade entre 35 e 74 anos (Média = $\approx 48,33$, Desvio Padrão = $\approx 9,56$). Os participantes foram enfermeiros (n=11), médicos (n=2), nutricionistas (n=2), fonoaudiólogos (n=1), biomédicos (n=1) e assistente social (n=1). Todas as participantes afirmaram ter experiência no manejo clínico de amamentação, variando de 2 a 25 anos de experiência (Média = $\approx 9,59$, Desvio Padrão = $\approx 6,16$).

5.2 Indicadores

A Tabela 3 apresenta as intenções usadas em cada rodada do procedimento de co-design. A primeira rodada teve 4 intenções e as rodadas restantes tiveram 6 intenções. Embora o número de intenções nas últimas três rodadas seja o mesmo, reorganizamos os problemas em intenções e modificamos o conteúdo para melhorar o fluxo da conversa. Esse rearranjo nos permitiu melhorar o desempenho do chatbot. A Tabela 3 também apresenta a média das pontuações de confiança para intenções usadas em cada rodada do procedimento de co-design.

A Figura 4 apresenta o número de participantes em cada rodada, na qual consideramos apenas aqueles que finalizaram a interação do chatbot (ou seja, chegaram ao final do fluxo conversacional). Houve aumento do número da primeira para a quarta rodada, o que ocorreu pelos seguintes motivos: (1) plataforma de interação, na qual o WhatsApp, aplicativo móvel de mensagens mais popular do Brasil, foi utilizado pelos participantes nas duas últimas rodadas; e (2) suporte e motivação presencial na última rodada, em que os pesquisadores atuaram pessoalmente explicando o funcionamento do chatbot e orientando os participantes na utilização do chatbot.

A Figura 5 apresenta o número de interações durante a abordagem de co-design. Na primeira e na segunda rodada, houve poucas interações, devido ao menor número de participantes (Figura 4). Ao contrário, houve muitas interações na quarta rodada devido à

Tabela 3 – Média dos índices de confiança para intenções usadas em cada rodada do procedimento de co-design.

Intenção	1	2	3	4	Média
Doação de leite humano	–	1,0	0,74	0,73	0,82
Notificação ativa de participantes	–	–	–	0,65	0,65
Pesquisa de satisfação	–	–	0,81	0,70	0,75
Posição e pega	0,95	0,98	0,86	0,73	0,88
Ingurgitamento	0,98	1,0	–	–	0,99
Hipogalactia e insegurança	0,93	0,97	0,96	0,73	0,89
Fissura	1,0	0,94	0,70	–	1,32
Abscesso mamário	–	0,98	–	–	0,98
Ingurgitamento mamário e abscesso	–	–	0,77	–	0,77
Abscesso, ingurgitamento e fissura mamária	–	–	–	0,73	0,73

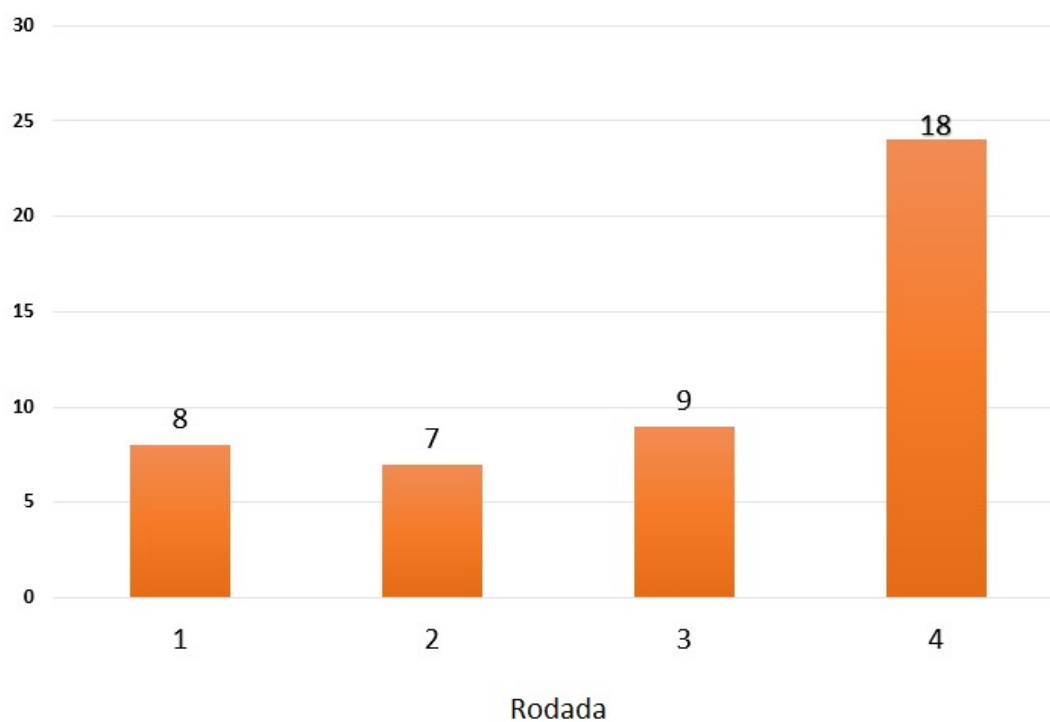


Figura 4 – Total de participantes em cada rodada do procedimento de co-design.

participação de mais profissionais de saúde na oficina presencial.

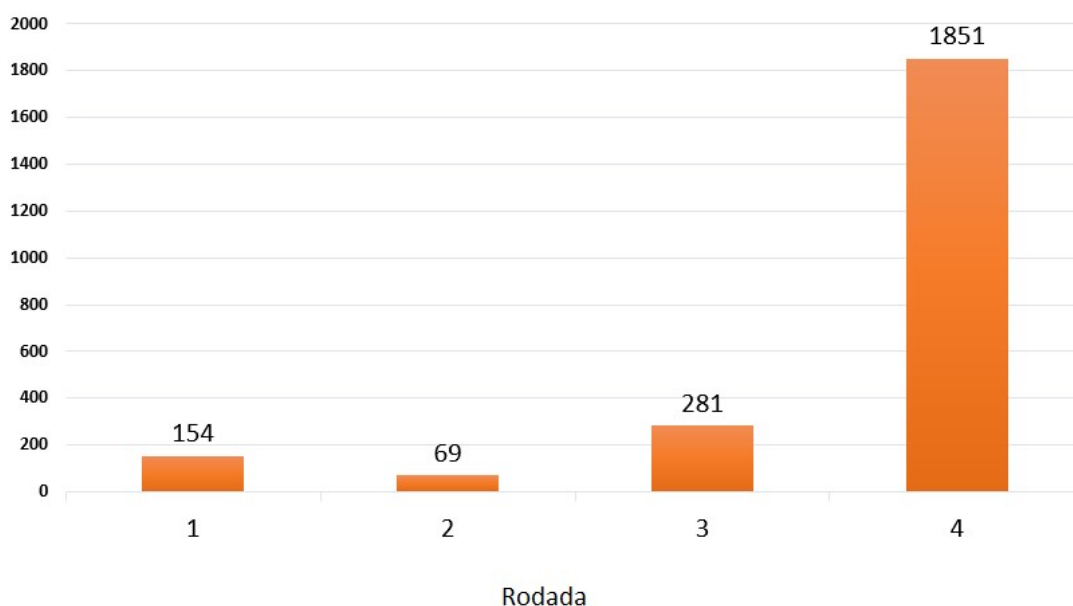


Figura 5 – Número de interações em cada rodada do procedimento de codesign.

5.3 Evolução dos resultados de desempenho

A Figura 6 apresenta um gráfico de linha com os resultados dos testes aplicados para os modelos de cada proposta de pipeline. Utilizamos a métrica de acurácia para medir o desempenho dos pipelines em cada rodada do procedimento de co-design. Com base nos resultados, os pipelines implantados em todas as rodadas foram, respectivamente: P3 com 0,82 de acurácia, P5 com 0,86, P5 com 0,81 e P4 com 0,93. Por fim, o pipeline P4, que utiliza a BERTimbau como *word embedding*, foi treinado com 100% dos dados, e então implantado na versão de produção do chatbot *Lhia*.

A Figura 7 exhibe o número de gatilhos de *fallback* nas rodadas de co-design. Com base nos resultados apresentados nas Figuras 5 e 7, os índices de *fallback* para todas as rodadas foram, respectivamente: $\approx 21\%$, 0% , $\approx 7\%$, e $\approx 15\%$.

5.4 Melhoria do Fluxo Conversacional

O fluxo conversacional utilizado no chatbot foi aprimorado com base nas sugestões e interações dos profissionais de saúde. O fluxo conversacional teve os seguintes números de enunciados para cada rodada, respectivamente: 217, 73, 457 e 2.904, conforme mostra a Figura 8. Esse aumento no número de respostas foi causado não apenas pelo aumento do número de participantes, mas também pelo aumento do tamanho (ou seja, número de enunciados) do fluxo conversacional. Embora a última rodada do procedimento de co-design tenha durado apenas 120 minutos (ao contrário das anteriores que duraram 7 dias), podemos ver bastante respostas do chatbot. Acreditamos que isso também se deve

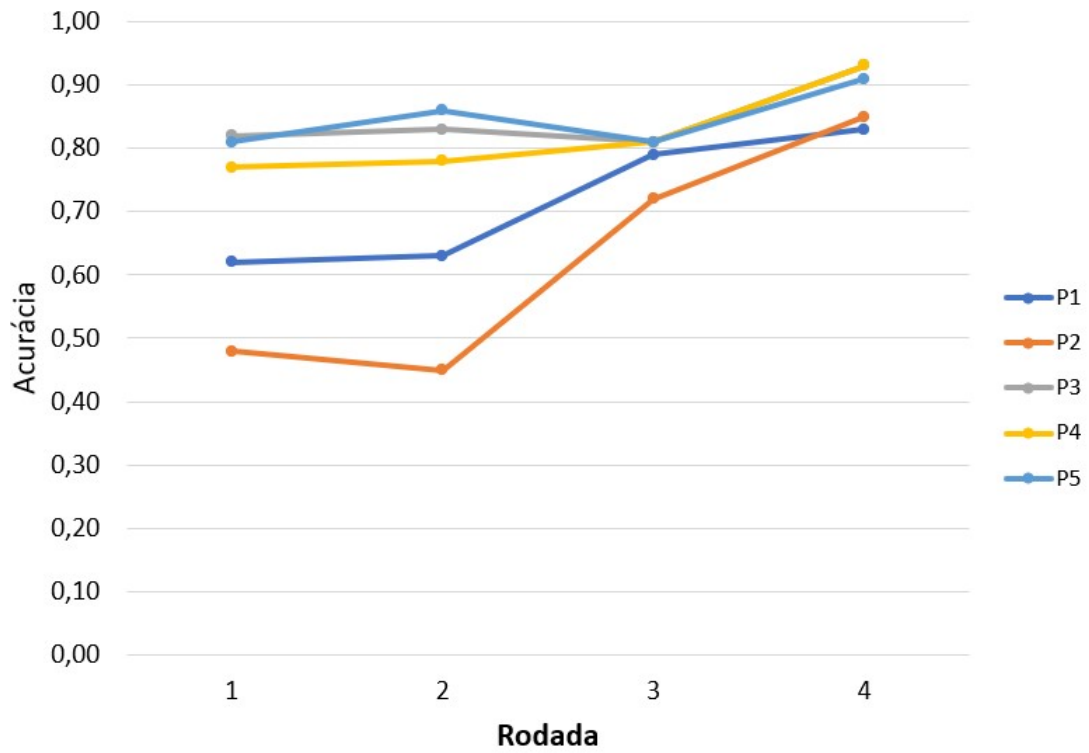


Figura 6 – Resultados de desempenho de cada pipeline para a métrica de acurácia nas rodadas de co-design.

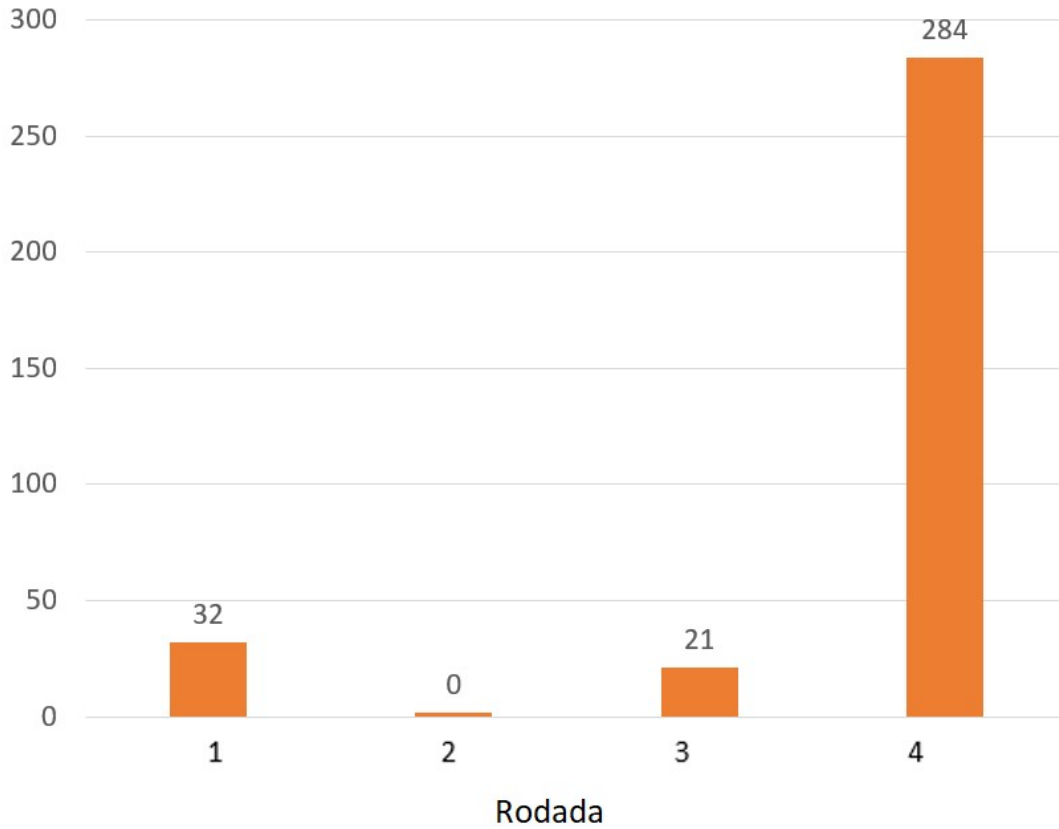


Figura 7 – Número de gatilhos de *fallback* em cada rodada do procedimento de co-design.

ao nosso suporte e motivação presencial, quando pudemos atuar pessoalmente explicando as funcionalidades do chatbot.




Figura 8 – Respostas do *Lhia* em cada rodada do procedimento de co-design.

A Figura 9 apresenta os resultados do NPS variando de 1 a 3 nas duas últimas rodadas, sendo 3 a melhor nota dada por um participante. Os resultados mostram uma evolução da pontuação, em que uma nota maior (3) é observada na quarta rodada.

5.5 Estudos de Caso

Para ilustrar o uso do chatbot *Lhia*, selecionamos conversas de um dos participantes do procedimento de co-design. A primeira conversa mostrada na Figura 10 mostra o usuário iniciando contato com o chatbot *Lhia* enviando uma mensagem “Oi”, a qual *Lhia* responde usando uma mensagem de saudação. A usuária então informa o problema que está sentindo durante a amamentação, que foi fissura. *Lhia*, ao receber a mensagem do usuário, faz 2 novas perguntas para entender melhor em qual intenção o problema relatado se enquadra, a saber “Existe relato de febre?” e “O bico do peito está ferido? (Tá doendo o mamilo?)”. Por fim, a partir das respostas dadas pelo usuário, o chatbot *Lhia* é capaz de identificar o problema, apresentando então informações textuais detalhadas sobre ele, suas causas e dicas de como lidar com o desconforto causado por ele.

A Figura 11 apresenta uma segunda conversa em que o chatbot orienta a usuária




Figura 9 – NPS resultado nas duas últimas rodadas do procedimento de co-design.

sobre como colocar o bebê na forma correta para amamentar. Para isso, são transmitidas orientações por meio de mensagens de texto e imagens. Na conversa, o chatbot pergunta se a usuária gostaria de receber uma imagem ilustrativa relacionada ao tema abordado: “Você quer ver uma imagem de como colocar o bebê?”. Ao final da conversa, o chatbot *Lhia* apresenta imagens em que uma mãe está sentada com seu bebê na posição correta para mamar.

A Figura 12 mostra *Lhia* iniciando uma conversa, ou seja, o mecanismo de notificação ativa, em que o próprio chatbot inicia a interação sem a necessidade de uma mensagem prévia do usuário. Nessa interação, o chatbot *Lhia* interage fornecendo informações sobre a importância do leite humano e sua doação ao BLH: “Você sabia? Um frasco de 100 ml de leite materno doado pode alimentar até 10 bebês internados na UTI!”. Os profissionais da saúde (ou seja, os participantes) acreditam que tal mecanismo pode estimular as mães a compreender e praticar a doação de leite humano. Por fim, o chatbot *Lhia* encerra a conversa informando que, caso a usuária tenha interesse em saber mais sobre a doação de leite humano, pode entrar em contato com o BLH do HU-UFMA via telefone ou ir até o endereço do BLH, ambos dados encaminhados nas mensagens da conversa.

A Figura 13 mostra uma interação na qual o chatbot *Lhia* não consegue entender a mensagem do participante (ou seja, um gatilho de *fallback*). Ele responde ao participante usando uma mensagem padrão (ou seja, a resposta de *fallback*) informando ao usuário que

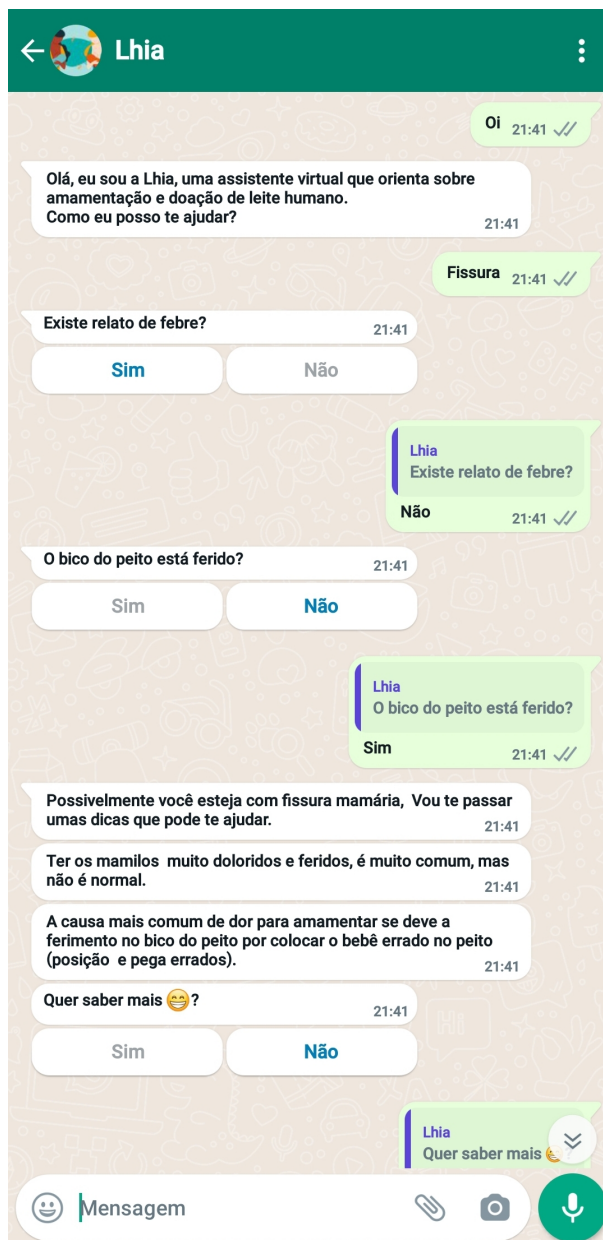


Figura 10 – Iniciando uma conversa com *Lhia*.

sua mensagem não foi compreendida e, em seguida, orientando para que a conversa seja retomada: “Desculpe, mas eu ainda estou aprendendo e por isso não consegui te entender. Para continuar, você pode digitar novamente o que deseja, mas em poucas palavras. Ex: Dor nos seios”.

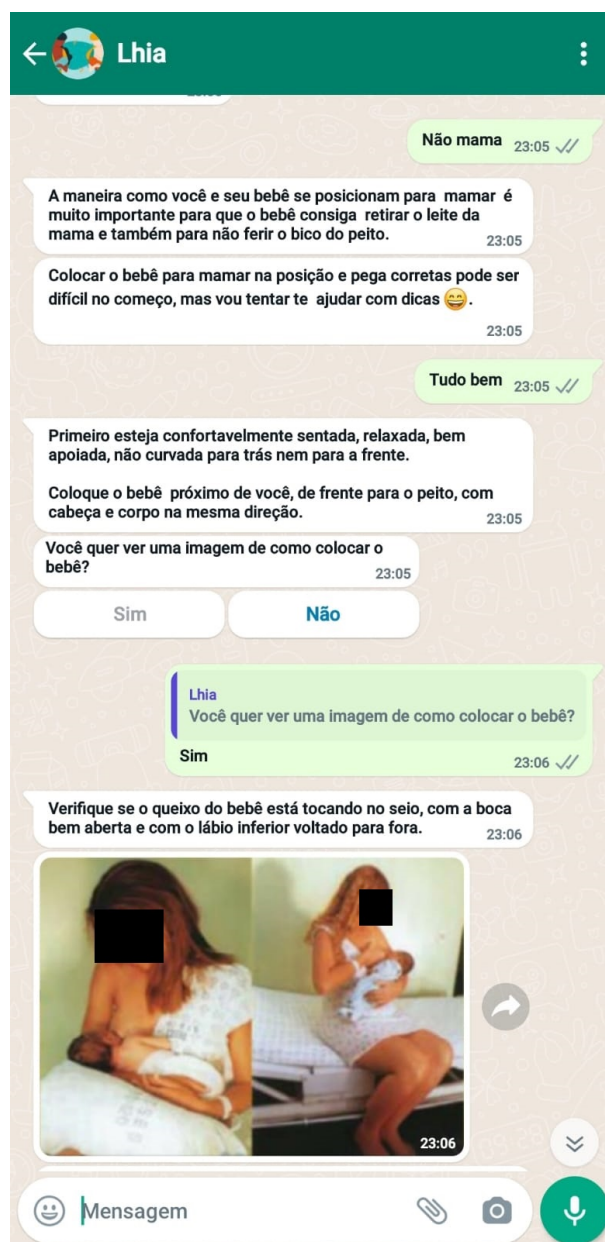


Figura 11 – *Lhia* orientando o usuário com textos e imagens.



Figura 12 – Exemplo do mecanismo de notificação ativa.

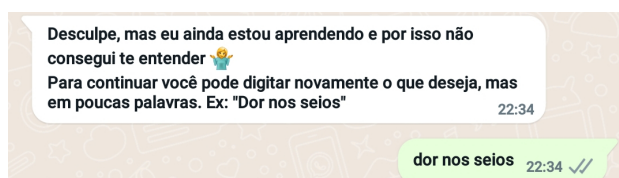


Figura 13 – Exemplo de uma resposta de *fallback*.

6 Discussão

Este capítulo apresenta uma discussão deste trabalho de mestrado, envolvendo o desenvolvimento do chatbot. Primeiramente, discutimos sobre os principais achados, ressaltando o potencial para ter boa adesão por parte dos usuários finais, e na sequência são apresentadas as limitações do estudo. O capítulo termina com a apresentação dos trabalhos futuros.

6.1 Principais Achados

Nossa solução proposta usa um pipeline de PLN baseado em AP para identificar quando a mãe procura atendimento no BLH para um problema específico de amamentação ou doação de leite humano. No desenvolvimento do chatbot *Lhia*, foi utilizada uma abordagem de co-design, que consistiu em ouvir os profissionais de saúde e utilizar as suas percepções e conhecimentos para melhorar o chatbot baseado em IA, simulando os textos produzidos por mães com possíveis problemas de amamentação e usando os dados de conversas gerados para rodadas sucessivas de treinamento e teste de diferentes pipelines de CLN baseados em AP. Além disso, durante o processo de co-design, houve ajustes no conteúdo do fluxo conversacional do chatbot (Figuras 8 e 9) com base nas sugestões dos profissionais de saúde.

Observando a última rodada do co-design, podemos observar que, embora o resultado da precisão do pipeline P5 tenha atingido 0,93 (Figura 6), o número de gatilhos de fallback aumentou para 284 (Figura 7) na quarta rodada, mas mantendo um gatilho de fallback em $\approx 15\%$. Isso certamente se deveu ao aumento do número de mensagens enviadas pelos usuários e à variabilidade das frases, causadas pelo número de participantes interagindo com *Lhia* e pelo apoio e motivação presencial durante a última rodada. Ao observar esses números, é possível verificar que o número de participantes (Figura 4) e interações (Figura 5) podem ser vistos como proporcionais, assim como as chances do chatbot *Lhia* de ser melhorado, pois tínhamos novos dados para serem utilizados em sessões de treinamento subsequentes de pipelines, portanto, maior a capacidade do *Lhia* de identificar os problemas relatados pelos usuários.

Durante o procedimento de co-design, os profissionais de saúde que participaram do estudo indicaram que o chatbot *Lhia* é uma ferramenta promissora para prevenir o desmame precoce das mães. Além disso, os participantes sugeriram que o chatbot é uma tecnologia interessante para apoiar a educação em amamentação de profissionais de saúde, cuidadores e familiares. Isso foi confirmado pelos resultados do NPS (Figura 9). Portanto, embora o *Lhia* seja resultado de um estudo inicial, ele tem potencial para ter boa adesão

por parte dos usuários finais, e ser constantemente melhorado mesmo após ser colocado em produção.

6.2 Limitações

O presente estudo está sujeito a uma série de limitações. Em primeiro lugar, nosso estudo foi limitado principalmente pela adesão dos participantes nas 3 primeiras rodadas do procedimento de co-design, demonstrada nos resultados. Em segundo lugar, do ponto de vista clínico, as barreiras à amamentação podem ocorrer em diferentes níveis (por exemplo, social, cultural e político) e em diferentes contextos, muitas vezes fora do controle materno. O *Lhia* foi concebido e desenvolvido considerando o contexto do BLH do HU-UFMA e utilizando a linguagem PT-BR. Portanto, nosso chatbot proposto pode não ser capaz de lidar com questões de amamentação em diferentes populações, não apenas por BLH fora do Brasil, mas também por usuários no Brasil, uma vez que possui uma área geográfica continental, com muitas regiões heterogêneas.

Em terceiro lugar, os dados fornecidos pelos profissionais de saúde para treinar pipelines foram textos simulando mensagens produzidas por mães com possíveis problemas de amamentação, que podem não ter sido fiéis ao que elas digitariam. Portanto, entendemos que estudos adicionais envolvendo mães são necessários não apenas para confirmar o desempenho do chatbot, mas também para melhorá-lo. Em quarto lugar, como *Lhia* procura educar por meio de informações sobre o manejo dos principais problemas relacionados à amamentação, na prática, não é capaz de abordar problemas que exijam intervenção de um profissional de saúde.

6.3 Trabalhos Futuros

Como temos uma versão mais estável do chatbot, pretendemos colocá-lo em produção para ser utilizado pelas lactantes atendidas no BLH do HU-UFMA. Os planos futuros para novos estudos incluem a realização de avaliações relacionadas à usabilidade e experiência do usuário explorando a versão de produção com mães, ao mesmo tempo, aplicando um processo chamado *Conversation-Driven Development (CDD)* (MALAMAS; SYMEONIDIS, 2021; SANTOS *et al.*, 2022). O CDD consiste em compartilhar o chatbot com os usuários finais, revisar conversas geradas regularmente, anotar as conversas e usá-las como dados de treinamento, testar o chatbot para verificar se seu comportamento é o esperado, rastrear falhas do chatbot, medir seu desempenho e corrigir quando ocorrem casos de conversas malsucedidas. Espera-se também que estudos clínicos com mães esclareçam o impacto do chatbot na percepção e atitude das pessoas em relação à amamentação.

O segundo estudo é uma validação técnica pré-clínica do chatbot, focado em

amamentação. Este trabalho visa realizar uma análise para verificar se há uma correlação entre os problemas da amamentação detectados pelo chatbot e os problemas identificados por profissionais de saúde com as mesmas mães participantes do estudo. O principal objetivo é identificar se o chatbot é uma ferramenta viável para detecção precoce de problemas relacionados à [AME](#).

Para finalizar, será realizado um estudo para identificar o impacto que o chatbot exerce sobre as mães que desejam amamentar exclusivamente durante os primeiros 6 meses de vida do recém-nascido. Neste estudo, o objetivo principal é identificar se o chatbot impacta positivamente a percepção da mãe quanto a sua capacidade de amamentar, além disso, o chatbot também será testado quando a sua capacidade em captar mães para serem doadoras de leite humano.

7 Considerações Finais

O chatbot desenvolvido neste estudo pode ser utilizado pelos BLH no processo de educação em amamentação e captação de doadoras de leite humano. O chatbot *Lhia* foi desenvolvido em uma abordagem de co-design com a participação de profissionais especializados em aleitamento materno. Assim, o resultado deste trabalho de mestrado é uma intervenção via Internet capaz de esclarecer os principais problemas relacionados à interrupção da amamentação, de forma não presencial, 24 horas por dia, 7 dias por semana. Como consequência, o chatbot proposto é capaz de fortalecer a proposta de política pública do BLH do HU-UFMA, pois expandirá suas fronteiras de atendimento, até mesmo para regiões remotas onde não há acesso a este serviço especializado de apoio, promoção e proteção da amamentação.

7.1 Contribuições

7.1.1 Científica e Social

Os objetivos da educação sobre amamentação são aumentar o conhecimento e as habilidades das mães, ajudá-las a ver a amamentação como normal e ajudá-las a desenvolver atitudes positivas em relação à amamentação (CDC, 2008). Desenvolver um chatbot que ajude mães que amamentam ou pessoas que apoiam a amamentação pode melhorar as taxas de amamentação na população em geral, e isso pode ser feito combinando conhecimento de intervenções via Internet e educação sobre amamentação.

Durante o cenário de pandemia da COVID-19, o distanciamento social foi exigido, com medidas restritivas que reduziram o acesso das pacientes aos profissionais de saúde, comprometendo a educação sobre amamentação nas unidades de saúde. Apesar dos benefícios do uso de chatbots para auxiliar na agilidade e continuidade do atendimento às pacientes (MONTENEGRO; COSTA; RIGHI, 2019), somos a primeira iniciativa que apresenta uma proposta de chatbot para melhorar os indicadores de amamentação na população brasileira e em PT-BR (MILNE-IVES *et al.*, 2020). Esta é a primeira proposta de criação de um chatbot inteligente treinado por profissionais de saúde formados que trabalham num BLH, correspondente a uma política pública de referência na promoção, proteção e apoio ao aleitamento materno. Portanto, o chatbot *Lhia* é considerado uma proposta inovadora de educação em amamentação no Brasil, podendo representar uma importante ferramenta de promoção da saúde.

7.1.2 Tecnológica

Recentemente, Kung et al. (KUNG *et al.*, 2023) apontou que chatbots generativos, como ChatGPT, Bard e Bing Chat, podem ter o potencial de auxiliar na educação médica e, potencialmente, na tomada de decisões clínicas. O chatbot *Lhia* se diferencia dos chatbots generativos atuais por ser desenvolvido em um processo de co-design com a participação de profissionais de saúde especializados em amamentação, disponibilizando conteúdo técnico validado por eles. O chatbot *Lhia* usa um pipeline de PLN baseado em AP para abordar problemas específicos de amamentação e, por meio da educação, ensinar o manejo correto de tais problemas. Também identifica a intenção das mães que desejam ser doadoras de leite humano e incentiva as mães a doarem leite humano por meio de notificações autônomas. Além disso, o chatbot *Lhia* se diferencia dos chatbots generativos por utilizar conteúdo multimídia, incluindo não apenas textos, mas também emojis e imagens ilustrativas.

7.2 Publicações

Durante o período de pesquisa deste mestrado, foi possível realizar as seguintes publicações de trabalhos científicos.

- Minicurso (capítulo de livro): *Desenvolvendo ChatBots com o Dialogflow* (CORREA; VIANA; TELES, 2021)
- Artigo: *Lhia: A Smart Chatbot for Breastfeeding Education and Recruitment of Human Milk Donors* (CORRÊA *et al.*, 2023)

Referências

- ABUSHAWAR, B.; ATWELL, E. Alice chatbot: Trials and outputs. *Computación y Sistemas*, v. 19, 12 2015. Citado na página 21.
- AGARWALA, H. *et al.* Development of an artificial conversational entity (ace) for continuous learning and adaptation to user's preferences and behavior. *Proceedings of the 18th Annual SIGdial Meeting on Discourse and Dialogue*, 2019. Disponível em: <https://www.di-lab.tum.de/fileadmin/w00byz/www/Horvath_Final_Documentation_WS18.pdf>. Citado na página 28.
- ALI, N. Chatbot: A conversational agent employed with named entity recognition model using artificial neural network. *Computation and Language (cs.CL); Artificial Intelligence (cs.AI)*, v. 1, Jun 2020. Citado na página 27.
- ALLOUCH, M.; AZARIA, A.; AZOULAY, R. Conversational agents: Goals, technologies, vision and challenges. *Sensors*, v. 21, n. 24, 2021. ISSN 1424-8220. Citado na página 23.
- ALMOHANNA, A. A.; WIN, K. T.; MEEDYA, S. Effectiveness of internet-based electronic technology interventions on breastfeeding outcomes: systematic review. *Journal of medical Internet research*, JMIR Publications Inc., Toronto, Canada, v. 22, n. 5, p. e17361, 2020. Citado na página 18.
- ARANHA, C. N. Uma abordagem de pré-processamento automático para mineração de textos em português: Sob o enfoque da inteligência computacional. *PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO DE JANEIRO - PUC-RIO*, Junho 2007. Citado 2 vezes nas páginas 21 e 24.
- AREVALILLO-HERRÁEZ, M.; ARNAU-GONZÁLEZ, P.; RAMZAN, N. On adapting the diet architecture and the rasa conversational toolkit for the sentiment analysis task. *IEEE Access*, v. 10, p. 107477–107487, 2022. Citado na página 37.
- BARRETO, I. C. de H. C. *et al.* Development and evaluation of the gissa mother-baby chatbot application in promoting child health. *Ciência e Saúde Coletiva*, v. 6, n. 5, p. 1679 – 1689, 2021. Citado na página 32.
- BINI, S. A. Artificial intelligence, machine learning, deep learning, and cognitive computing: what do these terms mean and how will they impact health care? *The Journal of arthroplasty*, Elsevier, v. 33, n. 8, p. 2358–2361, 2018. Citado 2 vezes nas páginas 26 e 27.
- BIRD, M. *et al.* A generative co-design framework for healthcare innovation: development and application of an end-user engagement framework. *Research Involvement and Engagement*, Springer Nature, v. 7, 2021. Citado na página 35.
- BOCKLISCH, T. *et al.* Rasa: Open source language understanding and dialogue management. *CoRR*, abs/1712.05181, 2017. Disponível em: <<http://arxiv.org/abs/1712.05181>>. Citado 2 vezes nas páginas 22 e 26.

- BOCKLISCH, T. *et al.* Rasa: Open source language understanding and dialogue management. *CoRR*, abs/1712.05181, 2017. Disponível em: <<http://arxiv.org/abs/1712.05181>>. Citado na página 28.
- Brasil, Ministério da Saúde. *SAÚDE DA CRIANÇA Aleitamento Materno e Alimentação Complementar*. Brasília, Brasil, 2015. Citado na página 17.
- BRAUN, B. *et al.* Evaluating natural language understanding services for conversational question answering systems. *Proceedings of the 18th Annual SIGdial Meeting on Discourse and Dialogue*, p. 174–185, Aug 2017. Citado na página 28.
- BULEGON, H.; MORO, C. M. C. Mineração de texto e o processamento de linguagem natural em sumários de alta hospitalar. *Journal of Health Informatics*, Junho 2010. ISSN 2175-4411. Citado 2 vezes nas páginas 24 e 25.
- BUNK, T. *et al.* DIET: lightweight language understanding for dialogue systems. *CoRR*, abs/2004.09936, 2020. Disponível em: <<https://arxiv.org/abs/2004.09936>>. Citado 2 vezes nas páginas 23 e 39.
- CDC. *Strategy 7. Access to Breastfeeding Education and Information*. 2008. <<https://www.cdc.gov/breastfeeding/pdf/strategy7-access-breastfeeding-education.pdf>>. Accessed: 2022-04-06. Citado 2 vezes nas páginas 30 e 53.
- CHUNG, K.; CHO, H. Y.; PARK, J. Y. A chatbot for perinatal women’s and partners’ obstetric and mental health care: Development and usability evaluation study. *JMIR Med Inform*, v. 9, n. 3, p. e18607, Mar 2021. ISSN 2291-9694. Citado na página 32.
- CORREA, J.; VIANA, D.; TELES, A. Desenvolvendo chatbots com o dialogflow. *Sociedade Brasileira de Computação*, 2021. Citado na página 54.
- CORRÊA, J. S. *et al.* Lhia: A smart chatbot for breastfeeding education and recruitment of human milk donors. *Applied Sciences*, v. 13, n. 12, 2023. ISSN 2076-3417. Citado na página 54.
- CSAKY, R. Deep learning based chatbot models. *Computation and Language*, v. 1, Aug 2019. Disponível em: <<https://arxiv.org/abs/1908.08835>>. Citado na página 27.
- DATA, W. L. C. in P. *EVERY NEWBORN An Action Plan To End Preventable Deaths*. [S.l.], 2014. Citado na página 15.
- DEMIRTAS, B. Strategies to support breastfeeding: a review. *International nursing review*, Wiley Online Library, v. 59, n. 4, p. 474–481, 2012. Citado na página 30.
- DEVLIN, J. *et al.* *BERT multilingual base model (cased)*. <<https://huggingface.co/bert-base-multilingual-cased>>. Accessed on 18 Jan 2022. Citado na página 39.
- DEVLIN, J. *et al.* *BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding*. 2019. Citado na página 39.
- EDWARDS, R. *et al.* Use of an interactive computer agent to support breastfeeding. *Maternal and child health journal*, v. 17, 01 2013. Citado na página 31.
- Fábio Souza and Rodrigo Nogueira and Roberto Lotufo. *BERTimbau Base*. <<https://huggingface.co/neuralmind/bert-base-portuguese-cased>>. Accessed on 18 Jan 2022. Citado na página 39.

- Fábio Souza and Rodrigo Nogueira and Roberto Lotufo. *BERTimbauLarge*. <<https://huggingface.co/neuralmind/bert-large-portuguese-cased>>. Accessed on 18 Jan 2022. Citado na página 39.
- FILHO, J. A. W. *et al.* The brWaC corpus: A new open resource for Brazilian Portuguese. In: *Proceedings of the Eleventh International Conference on Language Resources and Evaluation (LREC 2018)*. [S.l.]: European Language Resources Association (ELRA), 2018. Citado na página 40.
- FREIRE, E. A. de L. *et al.* Factors associated with early weaning in the brazilian context: a literature review. v. 4, p. 1343–1355, 2021. Citado na página 16.
- GAVINE, A. *et al.* Remote provision of breastfeeding support and education: Systematic review and meta-analysis. *Maternal & Child Nutrition*, Wiley Online Library, v. 18, n. 2, p. e13296, 2022. Citado na página 31.
- GEOGHEGAN-MORPHET, N. *et al.* Development and implementation of a novel online breastfeeding support resource: the maternal virtual infant nutrition support clinic. *Breastfeeding Medicine*, Mary Ann Liebert, Inc. 140 Huguenot Street, 3rd Floor New Rochelle, NY 10801 USA, v. 9, n. 10, p. 520–523, 2014. Citado na página 31.
- GIGLIA, R. *et al.* Exclusive breastfeeding increased by an internet intervention. *Breastfeeding Medicine*, Mary Ann Liebert, Inc. 140 Huguenot Street, 3rd Floor New Rochelle, NY 10801 USA, v. 10, n. 1, p. 20–25, 2015. Citado na página 30.
- GUPTA, J.; SINGH, V.; KUMAR, I. Florence- a health care chatbot. In: *2021 7th International Conference on Advanced Computing and Communication Systems (ICACCS)*. [S.l.: s.n.], 2021. v. 1, p. 504–508. Citado na página 26.
- HEALTH", B. M. of. *Cadernos de Atenção Básica - SAÚDE DA CRIANÇA - Aleitamento Materno e Alimentação Complementar*. [S.l.], 2015. Citado na página 36.
- HELM, J. M. *et al.* Machine learning and artificial intelligence: definitions, applications, and future directions. *Current reviews in musculoskeletal medicine*, Springer, v. 13, p. 69–76, 2020. Citado na página 26.
- KAPOČIŪTÈ-DZIKIENÈ, J. A domain-specific generative chatbot trained from little data. *Applied Sciences*, Applied Sciences, v. 10, n. 7, 2020. ISSN 2076-3417. Citado na página 23.
- KAR, R.; HALDAR, R. Applying chatbots to the internet of things: Opportunities and architectural elements. *Artificial Intelligence (cs.AI); Human-Computer Interaction (cs.HC)*, Nov 2016. Disponível em: <<https://arxiv.org/abs/1611.03799>>. Citado na página 22.
- KAR, R.; HALDAR, R. Applying chatbots to the internet of things: Opportunities and architectural elements. *International Journal of Advanced Computer Science and Applications*, The Science and Information Organization, v. 7, n. 11, 2016. ISSN 2158-107X. Disponível em: <<http://dx.doi.org/10.14569/IJACSA.2016.071119>>. Citado na página 23.
- KARVE, S. *et al.* Context sensitive conversational agent using dnn. In: *2018 Second International Conference on Electronics, Communication and Aerospace Technology (ICECA)*. [S.l.: s.n.], 2018. p. 475–478. Citado na página 21.

- KE, J.; OUYANG, Y.-Q.; REDDING, S. R. Family-centered breastfeeding education to promote primiparas' exclusive breastfeeding in china. *Journal of Human Lactation*, v. 34, n. 2, p. 365–378, 2018. Citado na página 30.
- KHURANA, D. *et al.* Natural language processing: state of the art, current trends and challenges. *Multimedia Tools and Applications*, v. 82, n. 3, p. 3713–3744, 2023. ISSN 1380-7501, 1573-7721. Citado 3 vezes nas páginas 16, 23 e 37.
- KROL, M. W. *et al.* The net promoter score – an asset to patient experience surveys? *Health Expectations*, v. 18, n. 6, p. 3099–3109, 2015. Citado na página 36.
- KUNG, T. H. *et al.* Performance of chatgpt on usmle: Potential for ai-assisted medical education using large language models. *PLoS digital health*, Public Library of Science, v. 2, n. 2, p. e0000198, 2023. Citado 2 vezes nas páginas 27 e 54.
- KUSAL, S. *et al.* Ai-based conversational agents: A scoping review from technologies to future directions. *IEEE Access*, IEEE, v. 10, p. 92337–92356, 2022. Citado 2 vezes nas páginas 20 e 23.
- LAMOUNIER, J. A. *et al.* Iniciativa hospital amigo da criança: 25 anos de experiência no brasil. *Revista Paulista de Pediatria*, SciELO Brasil, v. 37, p. 486–493, 2019. Citado na página 17.
- LAU, Y. *et al.* Efficacy of e-technologies in improving breastfeeding outcomes among perinatal women: a meta-analysis. *Maternal & Child Nutrition*, Wiley Online Library, v. 12, n. 3, p. 381–401, 2016. Citado na página 31.
- LEPTOURGOS, P.; CORLETT, P. R. Embodied predictions, agence, and psychosis. *Front Big Data*, v. 3, Aug 2020. Disponível em: <<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7931869/>>. Citado na página 20.
- LIGHT, M. *Journal of Logic, Language, and Information*, Springer, v. 7, n. 1, p. 111–114, 1998. ISSN 09258531, 15729583. Disponível em: <<http://www.jstor.org/stable/40180114>>. Citado na página 25.
- MALAMAS, N.; SYMEONIDIS, A. Embedding rasa in edge devices: Capabilities and limitations. *Procedia Computer Science*, v. 192, p. 109–118, 2021. ISSN 1877-0509. Knowledge-Based and Intelligent Information & Engineering Systems: Proceedings of the 25th International Conference KES2021. Citado na página 51.
- MCARTHUR, L.; OTTOSEN, M. J.; PICARELLA, L. Technology for breastfeeding support: a systematic review. *Journal of Informatics Nursing*, Anthony J. Jannetti, Inc., v. 3, n. 1, p. 21–32, 2018. Citado na página 31.
- MENESES, T. M. X. d.; OLIVEIRA, M. I. C. d.; BOCCOLINI, C. S. Prevalence and factors associated with breast milk donation in banks that receive human milk in primary health care units. *Jornal de pediatria*, SciELO Brasil, v. 93, p. 382–388, 2017. Citado na página 17.
- MILNE-IVES, M. *et al.* The effectiveness of artificial intelligence conversational agents in health care: Systematic review. *J Med Internet Res*, v. 22, n. 10, p. e20346, Oct 2020. Citado 2 vezes nas páginas 31 e 53.

MONTENEGRO, J. L. Z.; COSTA, C. A. da; RIGHI, R. da R. Survey of conversational agents in health. *Expert Systems With Applications*, v. 129, p. 56–67, 2019. Citado 4 vezes nas páginas 16, 17, 31 e 53.

MORAIS, E. A. M.; AMBRÓSIO, A. P. Mineração de textos. Dezembro 2007. Disponível em: <https://ww2.inf.ufg.br/sites/default/files/uploads/relatorios-tecnicos/RT-INF_005-07.pdf>. Citado na página 24.

NEGIN, J. *et al.* The influence of grandmothers on breastfeeding rates: a systematic review. *BMC pregnancy and childbirth*, Springer, v. 16, n. 1, p. 1–10, 2016. Citado na página 30.

NEIA, V. J. C. *et al.* Recomendações na doação de leite materno aos bancos de leite humano frente à pandemia do covid-19. *Research, Society and Development*, v. 10, n. 8, 2021. Citado na página 17.

Neurocognition and Natural Language Processing Research Lab. *BrWaC*. <<https://www.inf.ufrgs.br/pln/wiki/index.php?title=BrWaC>>. Accessed on 18 Jan 2022. Citado na página 40.

ORGANIZATION", W. H. *Infant and young child feeding: model chapter for textbooks for medical students and allied health professionals*. [S.l.], 2009. Citado 2 vezes nas páginas 15 e 36.

ORGANIZATION, W. H. *Call for proposals – Support for the development of WHO guidelines on donor human milk banking*. 2022. <<https://www.who.int/news-room/articles-detail/call-for-proposals-support-for-the-development-of-who-guidelines-on-donor-human-milk-banking>>. Accessed: 2023-01-09. Citado na página 15.

PACHECO, C.; PEREIRA, N. Deep learning conceitos e utilização nas diversas Áreas do conhecimento. v. 2, p. 34–49, 12 2018. Citado na página 27.

RAEISI, K. *et al.* A single center study of the effects of trained fathers' participation in constant breastfeeding. *Acta Medica Iranica*, p. 694–696, 2014. Citado na página 30.

Rasa. *Rasa framework*. 2021. <<https://rasa.com/docs/rasa/components/>>. Accessed: 2023-03-02. Citado na página 38.

ROLLINS, N. C. *et al.* Why invest, and what it will take to improve breastfeeding practices? *The Lancet*, Science Direct, v. 387, p. 491–504, 2016. Citado 2 vezes nas páginas 15 e 17.

RUEDEN, L. V. *et al.* Informed machine learning – a taxonomy and survey of integrating prior knowledge into learning systems. *IEEE TRANSACTIONS ON KNOWLEDGE AND DATA ENGINEERING*, May 2021. ISSN 1558-2191. Citado na página 26.

RUSSEL, S.; NORVIG, P. *et al.* *Artificial intelligence: a modern approach*. [S.l.]: Pearson Education Limited London, 2013. v. 256. Citado na página 26.

SAFI, Z. *et al.* Technical aspects of developing chatbots for medical applications: Scoping review. *Journal of Medical Internet Research*, v. 22, n. 12, p. e19127, 2020. Citado 2 vezes nas páginas 16 e 31.

- SANTOS, G. A. *et al.* A conversation-driven approach for chatbot management. *IEEE Access*, v. 10, p. 8474–8486, 2022. Citado na página 51.
- SANTOS, R. E. S. *et al.* Técnicas de processamento de linguagem natural aplicadas ao processamento de mineração de textos: Resultados preliminares de mapeamento sistemático. *Revista de Sistemas e Computação*, Jul 2014. Citado na página 24.
- SANTOS, T. R. *et al.* Reflexos do aleitamento materno e alimentação complementar: Uma abordagem na nutrição infantil. In: . [S.l.: s.n.], 2020. Citado na página 18.
- SASAKI, Y. *et al.* How to make the most of the dictionaries in statistical ner. *BMC Bioinformatics*, Nov 2008. Disponível em: <<https://pubmed.ncbi.nlm.nih.gov/19025691/>>. Citado na página 27.
- SILVA, A. A. M. da. Methodological aspects of the Brazilian national survey on child nutrition (enani-2019). *Reports in public health*, v. 37(8), p. e00172121, 2021. Citado na página 17.
- SILVA, A. C. R. e; BASTOS, R. P.; PIMENTEL, Z. N. de S. Early ab lactation: a systematic review. *Electronic Journal Collection Health*, v. 30, p. 1 – 10, 2019. Citado na página 15.
- SITRIN, D. *et al.* Improving newborn care practices through home visits: lessons from Malawi, Nepal, Bangladesh, and Uganda. *Global Health Action*, Taylor & Francis, v. 8, n. 1, p. 23963, 2015. Citado na página 30.
- SLATTERY, P.; SAERI, A. K.; BRAGGE, P. Research co-design in health: a rapid overview of reviews. *Health research policy and systems*, BioMed Central, v. 18, n. 1, p. 1–13, 2020. Citado na página 34.
- SONG, D.; OH, E. Y.; RICE, M. Interacting with a conversational agent system for educational purposes in online courses. In: IEEE. *2017 10th international conference on human system interactions (HSI)*. [S.l.], 2017. p. 78–82. Citado na página 21.
- SOUZA, F.; NOGUEIRA, R.; LOTUFO, R. Bertimbau: pretrained bert models for Brazilian Portuguese. In: SPRINGER. *Brazilian Conference on Intelligent Systems*. [S.l.], 2020. p. 403–417. Citado na página 39.
- TAJ, I.; JHANJHI, N. Towards industrial revolution 5.0 and explainable artificial intelligence: Challenges and opportunities. *International Journal of Computing and Digital Systems*, v. 12, p. 295–320, 07 2022. Citado na página 16.
- TANG, K. *et al.* Information and communication systems to tackle barriers to breastfeeding: systematic search and review. *Journal of Medical Internet Research*, JMIR Publications Inc., Toronto, Canada, v. 21, n. 9, p. e13947, 2019. Citado 2 vezes nas páginas 16 e 31.
- TANG, K. *et al.* Information and communication systems to tackle barriers to breastfeeding: Systematic search and review. *J Med Internet Res*, v. 21, n. 9, p. e13947, Sep 2019. ISSN 1438-8871. Citado na página 33.
- TURING, A. M. I.—COMPUTING MACHINERY AND INTELLIGENCE. *Mind*, LIX, n. 236, p. 433–460, 10 1950. ISSN 0026-4423. Disponível em: <<https://doi.org/10.1093/mind/LIX.236.433>>. Citado na página 20.

- UNICEF. *Innocenti Declaration*. 1990. <<http://worldbreastfeedingweek.org/2018/wp-content/uploads/2018/07/1990-Innocenti-Declaration.pdf>>. Accessed: 2023-01-05. Citado na página 17.
- UNICEF *et al.* *Convenção das Nações unidas sobre os direitos da criança*. 2012. Citado na página 17.
- VICTORA, C. G. *et al.* Breastfeeding in the 21st century: epidemiology, mechanisms, and lifelong effect. *The Lancet*, v. 387, n. 10017, p. 475–490, 2016. Citado na página 15.
- WEIZENBAUM, J. Eliza—a computer program for the study of natural language communication between man and machine. *Communications of the ACM*, v. 9, p. 36–45, Jan 1966. Disponível em: <<https://dl.acm.org/doi/10.1145/365153.365168>>. Citado na página 20.
- WOLF, T. *et al.* Huggingface’s transformers: State-of-the-art natural language processing. In: *Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing: System Demonstrations*. [S.l.]: Association for Computational Linguistics, 2020. p. 38–45. Citado na página 39.
- WONG, J. *et al.* A chatbot to engage parents of preterm and term infants on parental stress, parental sleep, and infant feeding: Usability and feasibility study. *JMIR Pediatr Parent*, v. 4, n. 4, p. e30169, Oct 2021. ISSN 2561-6722. Citado na página 31.
- World Health Organization. *Guideline: protecting, promoting and supporting breastfeeding in facilities providing maternity and newborn services*. Geneva, Switzerland, 2017. Citado na página 15.
- XU, L. *et al.* Chatbot for health care and oncology applications using artificial intelligence and machine learning: Systematic review. *JMIR Cancer*, v. 7, n. 4, p. e27850, Nov 2021. Citado na página 31.
- YADAV, D. *et al.* Feedpal: Understanding opportunities for chatbots in breastfeeding education of women in india. *Proc. ACM Hum.-Comput. Interact.*, v. 3, n. 170, p. 1–30, 2019. Citado na página 31.
- ZHANG, Z. *et al.* Maintaining continuity in longitudinal, multi-method health interventions using virtual agents: The case of breastfeeding promotion. In: *IVA: International Conference on Intelligent Virtual Agents*. Boston, MA, USA: Springer International Publishing, 2014. (14th International Conference), p. 504–513. Citado na página 31.
- ZHAO, W. X. *et al.* *A Survey of Large Language Models*. 2023. Citado 2 vezes nas páginas 23 e 24.