

**CENTRO UNIVERSITÁRIO DE MACEIÓ
CURSO DE CIÊNCIA DA COMPUTAÇÃO**

**BRUNO SOTERO OITICICA LIMA
ISABELLE DA SILVA OLIVEIRA
THIAGO ANDRES TABOADA DIDIER DE FREITAS**

PLATAFORMA WEB DE CHATBOT PARA ANÁLISE DE SENTIMENTOS

MACEIÓ, 17 DE JUNHO DE 2025.

BRUNO SOTERO OITICICA LIMA

ISABELLE DA SILVA OLIVEIRA

THIAGO ANDRES TABOADA DIDIER DE FREITAS

PLATAFORMA WEB DE CHATBOT PARA ANÁLISE DE SENTIMENTOS

Monografia apresentada ao Centro Universitário de Maceió como um dos pré-requisitos para a obtenção de grau de Bacharel em Ciência da Computação.

Orientador: Esp. Victor Brunno Dantas
De Souza Rosas

Maceió, AL

2025

BRUNO SOTERO OITICICA LIMA
ISABELLE DA SILVA OLIVEIRA
THIAGO ANDRES TABOADA DIDIER DE FREITAS

PLATAFORMA WEB DE CHATBOT PARA ANÁLISE DE SENTIMENTOS

Monografia apresentada ao Centro Universitário de Maceió como um dos pré-requisitos para a obtenção de grau de Bacharel em Ciência da Computação

Aprovada em 17 / 06 / 2025

Banca Examinadora

Esp. Victor Brunno Dantas De Souza Rosas

Centro Universitário de Maceió



Me. Izaac Duarte de Alencar

Centro Universitário de Maceió

Me. Marcos Vinicius Silva Bento
Centro Universitário de Maceió

Catalogação na fonte: Biblioteca do Centro Universitário de Maceió, Unima | Afya

L732p Lima, Bruno Sotero Oiticica
Plataforma web de Chatbot para apoio de suporte emocional / Bruno Sotero Oiticica Lima, Isabelle da Silva Oliveira, Thiago Andres Taboada Didier de Freitas ; orientação [de] Victor Brunno Dantas de Souza Rosas. – Maceió, 2025.
44 f. : il.

Trabalho de Conclusão de Curso (Graduação em Ciência da Computação) -Centro Universitário de Maceió – Unima | Afya, Maceió, 2025.

Inclui Bibliografias: p. 41-44.

1. Inteligência artificial. 2. Plataforma web. 3. Interação homem-máquina. I. Oliveira, Isabelle da Silva. II. Freitas, Thiago Andres Taboada Didier de. III. Rosas, Victor Brunno Dantas de Souza. (orient.). IV. Centro Universitário de Maceió. V. Título.

CDU: 004

Bibliotecária responsável: Adriele da Silva Lima CRB-4/1898

DEDICATÓRIA

“Dedico este trabalho a meus parentes mais próximos, especialmente ao meu tio que sempre esteve comigo em muitos momentos de felicidade que tive a oportunidade de viver.”

(Bruno Sotero)

“Dedico este trabalho aos meus pais e ao meu irmão, pela força, pelo apoio e por sempre confiarem em mim. Quando tudo pareceu noite, vocês foram a luz na minha escuridão.”

(Isabelle Oliveira)

“Dedico este trabalho ao meu companheiro e melhor amigo, Cactus Bond, cuja presença trouxe força, alegria e inspiração durante toda a caminhada.”

(Thiago Andres)

AGRADECIMENTOS

Agradeço especialmente a meus pais que sempre estiveram nessa jornada comigo mesmo nos momentos mais difíceis e em que pensei se estava fazendo a escolha certa. Dessa forma, sempre me apoiaram em todas as minhas decisões e mesmo quando discordavam de algo entendiam que eu deveria ser o guia do meu próprio destino.

Agradeço especialmente ao professor Izaac por todo o conhecimento adquirido ao longo desses anos e que me tornará um profissional capacitado e apaixonado pelo que faço no futuro.

Além disso, agradeço pela orientação do professor Victor Brunno que realizou um excelente trabalho em nos guiar durante todo esse processo, sua ajuda foi muito bem-vinda e faremos bom proveito dela.

(Bruno Sotero)

Agradeço, primeiramente, a Deus, que me guiou em todos os passos da minha vida e sempre me deu forças para continuar caminhando. Às vezes, o caminho parece longo e difícil, mas ter fé me fez ter a certeza de que tudo passa.

Aos meus pais, Maria e Marivaldo, por todo o apoio, confiança e cuidado. Sempre foram minha fonte de inspiração e dedicação. Fizeram e fazem tudo por mim, ter a confiança deles foi essencial para que eu chegasse até aqui.

Ao meu irmão João Marcos, que esteve comigo em todos os momentos longe dos meus pais, foi meu parceiro e me ajudou em todos os mínimos detalhes.

Aos meus amigos e colegas, em especial Thiago Taboada e Bruno Sotero, que estiveram comigo em todas as fases da graduação, tornando essa caminhada mais leve. Juntos, conseguimos ultrapassar todos os obstáculos que encontramos pelo caminho.

Ao Prof. Izaac Alencar, pelo apoio e amizade durante todos os anos. Seu companheirismo foi essencial para meu desenvolvimento, tanto acadêmico quanto pessoal. Serei sempre grata por todos os conselhos e também pelos puxões de orelha.

Agradeço, de forma especial, ao Prof. Victor Brunno, por nos orientar durante a realização deste trabalho. Sua ajuda foi fundamental para que pudéssemos concluir-lo.

Por fim, agradeço a todos os professores por todo o conhecimento compartilhado e pelo crescimento profissional que me proporcionaram, não apenas por me ensinarem, mas também por me fazer aprender.

(Isabelle Oliveira)

A conclusão deste trabalho seria impossível sem o apoio e incentivo de pessoas que, direta ou indiretamente, contribuíram para esta jornada.

Agradeço, primeiramente, aos meus pais, pelo amor incondicional, pela educação e pelos valores que me transmitiram ao longo da vida. O apoio constante, mesmo nos momentos mais difíceis, foi essencial para que eu pudesse chegar até aqui.

Aos meus amigos e colegas Isabelle Silva e Bruno Solteiro, agradeço pela amizade, companheirismo e pelas conversas e incentivos que me ajudaram a manter o foco e a motivação ao longo do percurso acadêmico.

Ao professor Izaac Alencar, sou grato pelo apoio e pela amizade durante todos os anos. Seu companheirismo foi fundamental para o meu desenvolvimento, tanto acadêmico quanto pessoal.

Por fim, deixo meus agradecimentos a todos os professores, pelo conhecimento compartilhado e pelo crescimento profissional que me proporcionaram — não apenas por ensinarem, mas por me ensinarem a aprender.

(Thiago Taboada)

RESUMO

Este trabalho tem como objetivo desenvolver uma plataforma web capaz de oferecer suporte psicológico inicial, utilizando um modelo de inteligência artificial treinado para identificar emoções em mensagens escritas. Parte-se da hipótese de que um sistema baseado em linguagem natural pode auxiliar no acolhimento de usuários que enfrentam dificuldades emocionais, especialmente como apoio complementar em contextos de acesso limitado ao atendimento psicológico tradicional. A proposta consiste na construção de um chatbot que reconhece intenções e emoções nas interações, fornecendo respostas adequadas de forma autônoma. A metodologia adotada foi dividida em cinco fases: (1) pesquisa e seleção de métodos e ferramentas; (2) configuração do ambiente de desenvolvimento; (3) elaboração do back-end; (4) construção da interface web; e (5) validação e integração entre o modelo treinado e a plataforma. Para demonstrar o funcionamento da plataforma, foram incluídas na seção de resultados diversas capturas de tela que ilustram o comportamento do sistema. Os resultados obtidos indicam que o sistema cumpre sua proposta, mesmo com limitações de recursos computacionais. A solução desenvolvida se mostra um protótipo funcional e promissor, com potencial para futuras melhorias e expansão em contextos mais amplos de saúde mental digital.

Palavras-chave: inteligência artificial; plataforma web; apoio psicológico.

ABSTRACT

This work aims to develop a web platform capable of offering initial psychological support, using an artificial intelligence model trained to identify emotions in written messages. The hypothesis is that a system based on natural language can assist in welcoming users who face emotional difficulties, especially as complementary support in contexts of limited access to traditional psychological care. The proposal consists of building a chatbot that recognizes intentions and emotions in interactions, providing appropriate responses autonomously. The adopted methodology was divided into five phases: (1) research and selection of methods and tools; (2) configuration of the development environment; (3) back-end elaboration; (4) construction of the web interface; and (5) validation and integration between the trained model and the platform. To demonstrate the platform's functioning, several screenshots were included in the results section to illustrate the system's behavior. The results obtained indicate that the system fulfills its purpose, even with computational resource limitations. The developed solution proves to be a functional and promising prototype, with potential for future improvements and expansion in broader digital mental health contexts.

Keywords: artificial intelligence; web platform; psychological support.

LISTA DE FIGURAS

Figura 1 -Tipos de chatbots	18
Figura 2 -Neurônio artificial de McCulloch e Pitts.	22
Figura 3 -Rede profunda	23
Figura 4 -Redução de Palavras no PLN.	26
Figura 5 -Fases da metodologia.....	29
Figura 6 -Fase de Pesquisa e seleção de ferramentas.	30
Figura 7 -Fase de Elaboração do Back-End	34
Figura 8 -Diagrama de Casos de Uso	38
Figura 9 -Diagrama de Classes	39
Figura 10 -Benefícios da plataforma	42
Figura 11 -Gráfico de Acurácia e Precisão do Modelo.....	43
Figura 12 -Tela Inicial	44
Figura 13 -Tela de Login.....	44
Figura 14 -Conversa com o Chat.....	45
Figura 15 -Conversa com o Chat no terminal	46
Figura 16 -Botão para agendar uma consulta	46
Figura 17 -Confirmação de agendamento de consulta.....	47
Figura 18 -QR Code para acesso ao repositório do GitHub do Back-end	55
Figura 19 -QR Code para acesso ao repositório do GitHub do Front-end.....	56

LISTA DE TABELAS

Tabela 1 - Exemplo de conjunto de dados estruturados	20
---	----

LISTA DE ABREVIATURAS E SIGLAS

API – *Application Programming Interface* (Interface de Programação de Aplicações)

BERT – *Bidirectional Encoder Representations from Transformers*

CSS – *Cascading Style Sheets* (Folhas de Estilo em Cascata)

DL – *Deep Learning* (Aprendizado Profundo)

GPT – *Generative Pre-trained Transformer*

GRU – *Gated Recurrent Unit* (Unidade Recorrente com Portões)

HTML – *HyperText Markup Language* (Linguagem de Marcação de Hipertexto)

HTTP – *HyperText Transfer Protocol*

IA – Inteligência Artificial

JSON – *JavaScript Object Notation*

LSTM – *Long Short-Term Memory*

ML – *Machine Learning* (Aprendizado de Máquina)

NER – *Named Entity Recognition* (Reconhecimento de Entidades Nomeadas)

NLTK – *Natural Language Toolkit*

NLP – *Natural Language Processing* (Processamento de Linguagem Natural)

ONNX – *Open Neural Network Exchange*

PLN – Processamento de Linguagem Natural

QoS – *Quality of Service* (Qualidade de Serviço)

RAM – *Random Access Memory* (Memória de Acesso Aleatório)

ReLU – *Rectified Linear Unit* (Unidade Linear Retificada)

REST – *Representational State Transfer*

RNN – *Recurrent Neural Network* (Rede Neural Recorrente)

ROM – *Read-Only Memory* (Memória Somente de Leitura)

RTSP – *Real-Time Streaming Protocol* (Protocolo de Transmissão em Tempo Real)

SpaCy – Biblioteca de Processamento de Linguagem Natural em Python

TPU – *Tensor Processing Unit*

SUMÁRIO

1. INTRODUÇÃO.....	14
2. OBJETIVOS.....	15
2.1 Objetivo Geral	15
2.2 Objetivos Específicos	15
3. ASPECTOS TEÓRICOS.....	16
3.1 Ansiedade e depressão.....	16
3.2 ChatBot	17
3.3 Inteligência Artificial.....	18
3.3.1 Aprendizado de Máquina (<i>Machine Learning</i>).....	19
3.3.2 Aprendizado Profundo (<i>Deep Learning</i>)	21
3.3.3 Teste de Turing	24
3.4 Processamento de Linguagem Natural – PLN	25
3.5 Análise de sentimentos	26
4. METODOLOGIA.....	28
4.1 Pesquisa e seleção de ferramentas	29
4.1.1 PyTorch	30
4.1.2 NLTK	30
4.1.3 Flask	31
4.1.4 Firebase.....	31
4.2 Configuração do Ambiente	33
4.3 Elaboração do Back-End	33
4.3.1 Arquitetura da Rede Neural	34
4.3.2 Processamento, Treinamento e Inferência do Modelo	35
4.4 Desenvolvimento da plataforma.....	36
4.4.1 Funcionalidades e Integração com Firebase	36
4.4.2 Modelagem do Sistema	37
4.7 Validação e Integração na Plataforma.....	39
4.7.1 Validação Técnica	40
4.7.2 Validação Funcional	40
4.7.3 Integração na Plataforma	40
4.7.4 Análise de Requisitos.....	41
5. RESULTADOS E DISCUSSÕES.....	41
5.1 Avaliação do Modelo Treinado	42

5.2 Apresentação da Plataforma	43
5.3 Comportamento do Chatbot.....	45
5.4 Funcionalidade de Agendamento	46
5.5 Dificuldades Encontradas	47
5.6 Reflexão sobre os Resultados	48
5.7 Comparação com Soluções Existentes	48
6. CONCLUSÕES.....	50
7. SUGESTÕES PARA TRABALHOS FUTUROS.....	51
REFERÊNCIAS.....	52
APÊNDICE A - Repositorio no GitHub do Back-end	55
APÊNDICE B - Repositorio no GitHub do Front-end	56

1. INTRODUÇÃO

O avanço das tecnologias digitais tem transformado profundamente a maneira como as pessoas interagem, trabalham e cuidam da saúde mental. Desde a popularização da internet nos anos 1990, surgiram novas possibilidades de suporte psicológico mediado por tecnologias, como os primeiros fóruns de apoio emocional online e os programas de aconselhamento virtual. (Eysenbach, 2001). Essas primeiras iniciativas, apesar de limitadas, abriram caminho para o desenvolvimento de ferramentas mais sofisticadas, capazes de oferecer suporte contínuo e personalizado.

Com o início do século XXI, o crescimento exponencial de dados digitais e a evolução dos algoritmos de aprendizado de máquina impulsionaram o surgimento de sistemas inteligentes em diferentes áreas, inclusive na saúde mental. Modelos de Inteligência Artificial foram progressivamente adaptados para analisar padrões de linguagem, emoções e comportamento dos usuários, permitindo intervenções mais ágeis e individualizadas. (Fitzpatrick, Darcy & Vierhile, 2017).

Simultaneamente, o campo do Processamento de Linguagem Natural (PLN) evoluiu, possibilitando que sistemas compreendessem melhor os sentimentos e intenções expressos nas mensagens de texto. Em 2018, o lançamento de modelos como o BERT (Bidirectional Encoder Representations from Transformers) elevou o nível de entendimento semântico em aplicações de IA, permitindo, entre outros avanços, a construção de chatbots mais sensíveis ao contexto emocional dos usuários. (Devlin et al., 2018).

Neste cenário, o uso de chatbots baseados em *deep learning* surge como uma alternativa promissora para ampliar o acesso a serviços de acompanhamento psicológico. A interação contínua e a capacidade de adaptação desses sistemas oferecem novas perspectivas para intervenções iniciais, triagem de casos e apoio psicológico cotidiano.

Assim, o presente trabalho propõe o desenvolvimento de uma plataforma de acompanhamento psicológico, integrando um chatbot treinado com técnicas de Inteligência Artificial e Aprendizado Profundo.

2. OBJETIVOS

2.1 Objetivo Geral

O desenvolvimento de uma plataforma web de acompanhamento psicológico integrada a um modelo de Inteligência Artificial e *Deep Learning*.

2.2 Objetivos Específicos

- Desenvolver um modelo que seja capaz de ler e interpretar as mensagens enviadas pelo usuário e responder da melhor forma possível;
- Aliar o uso da tecnologia com o trabalho dos profissionais de saúde mental no apoio a transtornos psicológicos.;
- Compreender como o modelo identifica cada sentimento humano e orienta a ele.

3. ASPECTOS TEÓRICOS

Esta seção apresenta os principais fundamentos teóricos que sustentam o desenvolvimento deste trabalho. São abordados temas como saúde mental, tecnologias emergentes e técnicas computacionais relevantes para a proposta.

3.1 Ansiedade e depressão

Ansiedade e depressão são transtornos mentais prevalentes que afetam significativamente a qualidade de vida das pessoas. A ansiedade caracteriza-se por sentimentos de preocupação excessiva, nervosismo e tensão, enquanto a depressão envolve uma sensação persistente de tristeza, perda de interesse em atividades e baixa energia. (MEDLEY,2023)

Mais de 300 milhões de pessoas em todo o mundo enfrentam a depressão. No Brasil, esse problema atinge cerca de 11,5 milhões de indivíduos diagnosticados. Porém, as dificuldades emocionais vão além da depressão. A ansiedade também representa uma questão séria, afetando aproximadamente 18,6 milhões de brasileiros em 2017, o que corresponde a quase 10% da população do país. (OMS,2022)

A pandemia causada pelo novo coronavírus gerou impactos psicológicos profundos na população. De acordo com a Organização Mundial da Saúde (OMS), no primeiro ano da pandemia de COVID-19, a prevalência global de ansiedade e depressão aumentou em 25%, uma das principais razões para o aumento dos casos foi o estresse sem precedentes provocado pelo isolamento social durante a pandemia. Esse cenário foi agravado pelas restrições ao trabalho, pela dificuldade de buscar apoio junto a familiares e pela limitação do envolvimento nas comunidades. Esses fatores podem provocar alterações emocionais nos indivíduos, resultando em um aumento dos sintomas de ansiedade e depressão, que podem persistir mesmo após o fim do surto. (BROOKS SK, et al., 2020).

A tecnologia tem ganhado espaço na psicologia, com ferramentas como chatbots para suporte emocional. No entanto, especialistas alertam que, embora a inteligência artificial possa ajudar a aliviar sintomas de alguns transtornos, ela não substitui a psicoterapia feita por profissionais. Assim, é indispensável que essas tecnologias sejam usadas como complemento, e não como substitutas, do atendimento especializado em saúde mental. (OPAS, 2022)

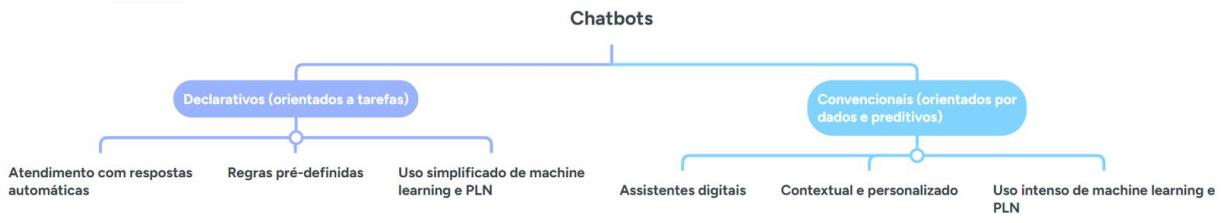
3.2 ChatBot

O termo refere-se a um programa de computador desenvolvido para interagir com os usuários de maneira semelhante à comunicação humana, fornecendo respostas condizentes com as perguntas formuladas. À medida que o software é submetido a processos de treinamento, suas respostas tornam-se progressivamente mais personalizadas, proporcionando uma experiência mais fluida e alinhada às necessidades específicas de cada usuário (ORACLE, 2020).

De modo geral, os ChatBots podem ser classificados em duas categorias principais (ORACLE, 2020):

- ChatBots orientados a tarefas (**declarativos**): aplicados em contextos específicos, são projetados para oferecer um atendimento eficiente por meio de respostas automatizadas em interações com o usuário. Seu funcionamento eficaz baseia-se principalmente em regras de linguagem natural, que visam possibilitar aos computadores a interpretação e manipulação da linguagem humana em grandes volumes de dados textuais e fontes não estruturadas. Embora possam empregar técnicas de machine learning, este não é seu foco principal (ORACLE, 2020).
- ChatBots orientados por dados e preditivos (convencionais): também denominados assistentes digitais ou virtuais, têm como objetivo proporcionar um atendimento mais personalizado, fundamentado no contexto e em análises preditivas. Esses modelos fazem uso intensivo de linguagem natural e apresentam uma ênfase significativa em técnicas de machine learning, sendo, portanto, considerados tecnologicamente mais avançados, ainda que representem uma parcela menor do mercado atual de soluções tecnológicas (ORACLE, 2020).

Figura 1-Tipos de chatbots



Fonte: Autores. (2025)

Neste trabalho, visamos desenvolver uma inteligência artificial eficiente para fornecer um atendimento adequado a usuários acometidos por transtornos mentais que estejam interferindo diretamente em sua qualidade de vida. O funcionamento ocorre a partir de um treinamento preciso com informações adequadas para uma análise eficiente do problema.

Entre as técnicas utilizadas no programa, temos as já citadas anteriormente, como as de machine learning, nas quais, a partir de uma análise dos dados obtidos, temos a identificação de padrões para a tomada de decisões e ações necessárias no projeto. Entre outras, temos o deep learning, que busca simular o funcionamento do cérebro humano a partir de redes neurais de múltiplas camadas, sendo útil quando se possui um grande volume de dados.

3.3 Inteligência Artificial

Russell e Norvig (2013) definem a Inteligência Artificial (IA) como uma área de estudo profundamente multidisciplinar, envolvendo conhecimentos de matemática, estatística, ciência da computação, filosofia, neurociência, entre outros campos. A investigação sobre a possibilidade de criar máquinas inteligentes remonta à década de 1940, quando Warren McCulloch e Walter Pitts, em 1943, propuseram um modelo computacional baseado no funcionamento dos neurônios biológicos. Seu modelo se baseava tanto no entendimento das funções básicas dos neurônios no cérebro quanto na recém-criada teoria da computação de Alan Turing. A partir dessa junção de ideias, McCulloch e Pitts demonstraram que qualquer função computável poderia ser processada por redes neurais artificiais e sugeriram que, com a configuração correta, essas redes teriam potencial para aprender e generalizar comportamentos. (Russell e Norvig, 2013)

Em 1956, durante uma conferência histórica organizada por John McCarthy em Dartmouth, foi lançada oficialmente a proposta de desenvolver máquinas que simulassesem aspectos da inteligência humana. McCarthy e seus colegas partiram da ideia de que “cada

aspecto da aprendizagem [...] pode, em princípio, ser descrito tão precisamente a ponto de ser construída uma máquina para simulá-lo" (RUSSEL; NORVIG, 2013). Esse evento é considerado o marco inicial da IA como área de pesquisa formal. Desde então, consolidou-se a concepção de que as máquinas poderiam ser treinadas para resolver problemas complexos, tradicionalmente encarados como exclusivos do raciocínio humano, e que poderiam, ainda, evoluir continuamente a partir de novas experiências e dados.

Faceli et al. (2021) apontam que, com o surgimento de desafios computacionais mais exigentes e o crescimento exponencial da geração de dados em áreas como ciência, indústria e comunicação, surgiu a necessidade de criar sistemas mais autônomos. Para lidar com essa realidade, foram desenvolvidas ferramentas capazes de realizar tarefas sem supervisão humana constante, abrindo caminho para uma diversidade de aplicações práticas. Entre as principais subáreas da Inteligência Artificial estão o Processamento de Linguagem Natural, que permite às máquinas compreenderem e gerarem linguagem humana; a Representação do Conhecimento, que organiza e estrutura informações complexas; e a Visão Computacional, que interpreta e analisa imagens e vídeos. Essas tecnologias já se fazem presentes em setores críticos como medicina, segurança pública, marketing e transportes inteligentes.

Segundo Ludermir (2021), dentro do vasto universo da Inteligência Artificial, destaca-se o Aprendizado de Máquina, que consiste no desenvolvimento de algoritmos capazes de aprender padrões e tomar decisões a partir de dados. Um subcampo ainda mais especializado desse ramo é o Aprendizado Profundo, que utiliza redes neurais artificiais profundas para processar grandes volumes de dados de maneira hierárquica e sofisticada. Essas redes, compostas por múltiplas camadas de processamento, são capazes de extrair representações cada vez mais abstratas da informação, permitindo avanços em áreas como reconhecimento de voz, tradução automática, diagnóstico médico assistido por IA, entre outros.

A Figura 1 ilustra esses subcampos da inteligência artificial, enquanto os tópicos 3.3.1 e 3.3.2 explicam as definições de Aprendizado de Máquina e Aprendizado Profundo, respectivamente.

3.3.1 Aprendizado de Máquina (*Machine Learning*)

Segundo Faceli et al. (2021), as aplicações que utilizam aprendizado de máquina se baseiam em modelos matemáticos capazes de capturar e representar padrões presentes em conjuntos de dados estruturados. Esses conjuntos geralmente são organizados em tabelas, onde

cada linha corresponde a uma observação contendo informações quantitativas (numéricas) ou qualitativas (categóricas) e cada coluna representa um atributo específico, isto é, uma característica ou dimensão relevante da observação analisada. Essa organização de dados facilita a aplicação de algoritmos de aprendizado para extração de conhecimento ou predição de valores futuros.

Ainda conforme Faceli et al. (2021), os atributos de um conjunto de dados estruturado podem ser classificados em duas categorias: os atributos preditivos, que compõem o vetor de entrada para os modelos de aprendizado de máquina, e o atributo alvo, que representa o valor que se deseja prever ou classificar. De maneira geral, o processo de aprendizado envolve a utilização dos valores dos atributos preditivos para inferir ou estimar o valor do atributo alvo, seja ele quantitativo (como uma medida numérica) ou qualitativo (como uma categoria ou classe).

A Tabela 1 exemplifica um conjunto de dados estruturados para um cenário de análise de interações com um ChatBot. Os dados incluem observações que combinam informações quantitativas e qualitativas, organizadas segundo os seguintes atributos: identificação da mensagem (ID); origem da mensagem (Sender), que pode ser o usuário ou o sistema; Tag, representando o sentimento identificado (por exemplo, tristeza ou paranóia); conteúdo textual da Mensagem; e o grau de confiança do modelo na identificação do sentimento (Confidence), expresso em valores contínuos de 0 a 1.

Tabela 1 - Exemplo de conjunto de dados estruturados

ID	Sender	Tag	Mensagem	Confidence
001	User	Saudação	Olá	0.808
002	System	Response	Oi! Como posso te ajudar?	
003	User	Paranóia	acho que todos me odeiam	0.999
004	System	Response	Você está seguro aqui para falar sobre o que está passando. Estou aqui para te ouvir	

Fonte: Autores. (2025)

Segundo Faceli et al. (2021), a estrutura clássica do Aprendizado de Máquina organiza essa área em duas categorias principais: aprendizado supervisionado e aprendizado não supervisionado. No aprendizado supervisionado, os dados apresentados ao modelo já contêm o atributo alvo previamente identificado, e o objetivo da inteligência artificial é aprender a prever corretamente o valor desse atributo em novas observações que ainda não foram rotuladas. Se o

valor a ser previsto for categórico, o problema é conhecido como classificação; se for numérico e contínuo, trata-se de um problema de regressão (LUDERMIR, 2021).

Considerando a Tabela 1, por exemplo, é possível construir um modelo supervisionado para estimar o Valor de Mercado dos imóveis, utilizando atributos como Área (m²), Quartos, Garagem, Tipo e Localização como variáveis preditivas. Nesse caso, o modelo estaria resolvendo um problema de regressão, pois a saída desejada, o valor de venda do imóvel é representado por um número real.

Por sua vez, no aprendizado não supervisionado, o conjunto de dados não contém rótulos no atributo alvo, e o modelo precisa identificar padrões ou agrupamentos apenas com base nas características disponíveis (LUDERMIR, 2021). Aplicando essa abordagem ao exemplo da Tabela 1, um algoritmo poderia formar grupos de imóveis similares, considerando fatores como metragem, número de quartos e existência de garagem. Após o agrupamento, caberia a uma análise posterior interpretar o significado desses grupos, como, por exemplo, imóveis de alto, médio ou baixo padrão de mercado.

3.3.2 Aprendizado Profundo (*Deep Learning*)

Segundo Faceli et al. (2021), “na busca pela construção de máquinas inteligentes, ou com comportamento inteligente, um modelo que ocorre naturalmente é o do cérebro humano”. Com base nesse princípio, surgiram os modelos de inteligência artificial conhecidos como Redes Neurais Artificiais, que se inspiram diretamente na estrutura e no funcionamento do sistema nervoso humano, buscando replicar, em algum nível, o processo de aprendizado utilizado pelo cérebro na aquisição de conhecimento.

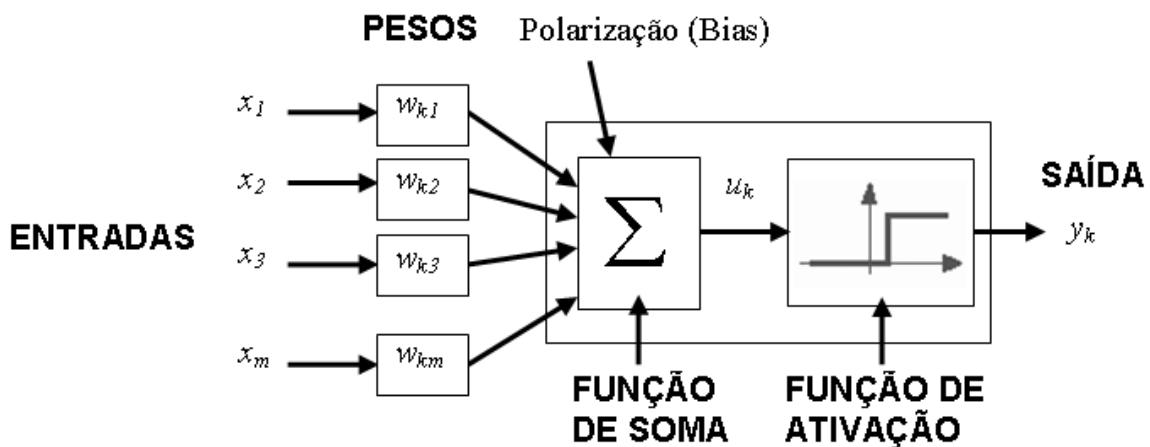
Os primeiros estudos sobre redes neurais artificiais foram realizados na década de 1940 e, desde então, essa área tem recebido investimentos contínuos e expressivos. Atualmente, as redes neurais artificiais figuram entre as técnicas mais eficazes da inteligência artificial, sendo aplicadas com sucesso na solução de problemas complexos em diversos setores, como medicina, finanças, transporte e tecnologia da informação (FACELI et al., 2021).

De maneira geral, uma rede neural artificial é composta por unidades básicas de processamento, conhecidas como “neurônios artificiais”, que executam operações matemáticas específicas. Esses neurônios são organizados em camadas e interligados por conexões que possuem pesos, responsáveis por ajustar a influência de cada entrada. Durante o processo de

aprendizado, os valores desses pesos são continuamente atualizados, incorporando assim o conhecimento que a rede adquire. (BRAGA et al., 2007 apud FACELI et al., 2021).

A Figura 2 ilustra um modelo simplificado de um neurônio artificial. Nesse esquema, cada entrada do neurônio é multiplicada por um peso, e todas as entradas ponderadas são combinadas por meio de uma função matemática f . O resultado dessa função constitui a saída do neurônio, que, por sua vez, pode servir como entrada para outros neurônios subsequentes na rede (FACELI et al., 2021).

Figura 2-Neurônio artificial de McCulloch e Pitts.



Fonte: Alcântara Santana, Robson. (2010).

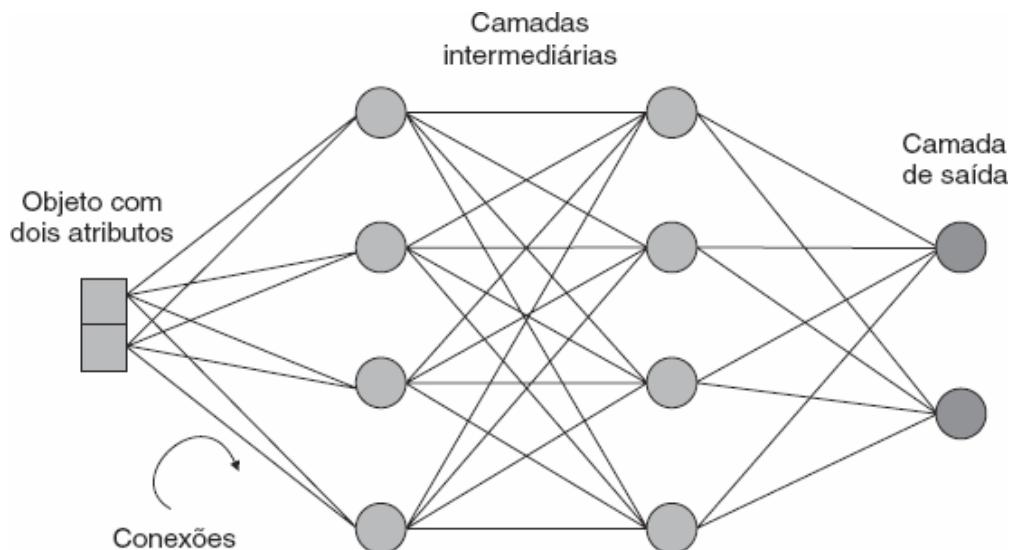
Conforme Faceli et al. (2021), redes profundas correspondem a redes neurais artificiais que possuem, no mínimo, duas camadas intermediárias entre a entrada e a saída. Essas redes, geralmente, são treinadas utilizando algoritmos de aprendizado profundo, como o backpropagation. Nesse processo, calcula-se o erro entre a saída real da rede e o valor esperado; esse erro é então propagado de volta pelas camadas intermediárias, procedimento conhecido como retropropagação para ajustar os pesos das conexões. O ajuste ocorre repetidamente até que o erro seja minimizado ou atinja um valor aceitável.

No presente trabalho, utilizando a biblioteca PyTorch, foi implementada uma rede neural profunda para a tarefa de classificação supervisionada de cadeias de texto (mensagens). O modelo é treinado a partir de dados rotulados, ou seja, cada mensagem possui uma categoria associada (como, por exemplo, “spam” ou “não spam”), permitindo à rede aprender a reconhecer padrões linguísticos relevantes para realizar a classificação. O treinamento também

emprega o algoritmo de backpropagation, ajustando os pesos internos da rede com o objetivo de maximizar a acurácia na categorização das novas mensagens.

A Figura 3 representa uma rede neural com camadas intermediárias (ocultas) entre a entrada e a saída. Cada neurônio está conectado aos neurônios da próxima camada, formando uma rede densa utilizada em tarefas de classificação, regressão e outras aplicações de aprendizado profundo.

Figura 3-Rede profunda



Fonte: Faceli et al. (2021)

Modelos de deep learning e Inteligência Artificial (IA) podem ser utilizados em diversas áreas além de chatbots, como no reconhecimento de padrões complexos em grandes volumes de dados. Algoritmos de deep learning são frequentemente aplicados ao Processamento de Linguagem Natural (PLN), onde redes neurais treinadas podem interpretar e gerar linguagem humana com uma profundidade sem precedentes, melhorando a interação de máquinas com usuários em diversos contextos. Modelos como o BERT e Redes Neurais Recorrentes (RNNs), incluindo LSTM e Bi-LSTM, têm se destacado em tarefas como a análise de sentimentos e reconhecimento de intenções em textos. (Kaushik et al., 2024).

Além disso, as técnicas de aprendizado por reforço vêm sendo aplicadas no aprimoramento da tomada de decisão autônoma por sistemas inteligentes, permitindo que esses sistemas melhorem continuamente seu desempenho com base nas interações anteriores. Este tipo de abordagem é utilizado, por exemplo, em assistentes virtuais e sistemas de recomendação, que podem evoluir de acordo com as preferências e comportamentos dos

usuários, ajustando suas respostas e sugestões de forma dinâmica e personalizada (Kaushik et al., 2024).

O uso de deep learning vai impactando setores como educação, saúde, e atendimento ao cliente, onde análise de sentimentos e reconhecimento de intenção são aplicados para criar experiências mais intuitivas e empáticas. Um exemplo de sucesso nesse contexto é o Dentbot, um chatbot específico para a educação odontológica. A utilização de modelos como LSTM e Bi-LSTM permitiu taxas de precisão elevadas, alcançando 89%, enquanto o modelo BERT superou com uma taxa de precisão de 94%, destacando o poder das redes profundas para personalizar a experiência e compreender o conteúdo de forma mais eficaz. (Araminta et al., 2024).

3.3.3 Teste de Turing

O Teste de Turing, proposto em 1950 pelo renomado matemático e cientista da computação Alan Turing em seu artigo seminal *Computing Machinery and Intelligence*, publicado na revista *Mind*, constitui um marco histórico no desenvolvimento da Inteligência Artificial (IA). Por meio desse experimento, Turing apresentou uma abordagem prática para refletir sobre a clássica e complexa questão: “As máquinas podem pensar?”. Em vez de se prender a definições filosóficas do termo “pensar”, ele propôs um método observável, baseado na capacidade de uma máquina simular uma conversa humana de forma convincente (A. M. TURING, 1950).

Na primeira parte do artigo, Turing apresentou o chamado “Jogo da Imitação”, que envolve três participantes: um homem, uma mulher e um juiz que se comunicam apenas por mensagens escritas, estando em salas separadas. O objetivo do homem e da mulher é enganar o juiz, fazendo-o acreditar que são o oposto do seu gênero real. Posteriormente, Turing propôs uma variação em que um dos participantes é substituído por um computador. Essa versão ficou conhecida como o “Teste de Turing” (ONODY, 2021).

É fundamental compreender que o Teste de Turing não visa avaliar se uma máquina possui consciência ou capacidade de raciocínio filosófico. Em vez disso, o teste se concentra na habilidade da máquina de replicar, de forma convincente, a comunicação humana linguística. Ou seja, uma máquina que passa no teste não necessariamente entende ou vivencia o que

comunica; o essencial é que consiga sustentar uma conversa suficientemente fluida para convencer um ser humano de que está interagindo com outra pessoa.

3.4 Processamento de Linguagem Natural – PLN

O Processamento de Linguagem Natural (PLN) é um campo da Inteligência Artificial que foca em permitir que as máquinas e sistemas computacionais entendam e processem a linguagem humana. Ele envolve o desenvolvimento de algoritmos e modelos que podem analisar, interpretar e gerar linguagem humana de forma significativa. Ao dissecar a estrutura gramatical das frases através da análise sintática, o PLN possibilita a compreensão das relações entre as palavras. A análise semântica concentra-se em compreender o significado das palavras e frases dentro de um contexto específico. (Scalabrin, E.E. (2025)).

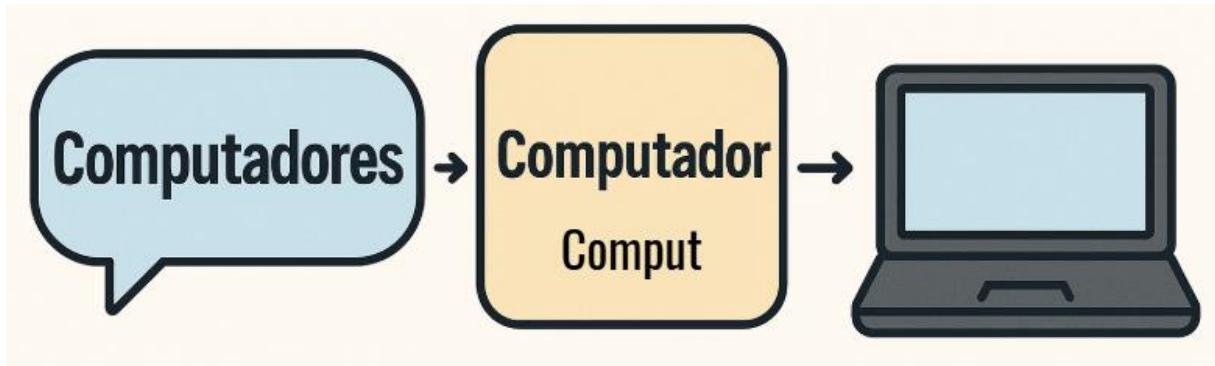
Além disso, o PLN também abrange áreas como a extração de informações, onde o objetivo é identificar dados relevantes dentro de um grande conjunto de textos. Isso pode incluir a extração de nomes de pessoas, organizações, locais, datas, entre outros elementos importantes. Outra área essencial é a análise de sentimentos, que procura determinar a opinião ou emoção por trás de um texto, como, por exemplo, se uma mensagem expressa um sentimento positivo, negativo ou neutro.

O PLN é especialmente importante em sistemas de assistentes virtuais e chatbots, que utilizam técnicas de compreensão de linguagem para interagir de maneira mais eficiente com os usuários. Modelos como o BERT e o GPT (que é a base deste assistente) são exemplos de redes neurais treinadas com grandes volumes de texto, permitindo a compreensão semântica mais profunda e a geração de respostas mais naturais e contextualmente precisas.

Uma das grandes dificuldades do PLN é a ambiguidade da linguagem natural. A mesma palavra pode ter diferentes significados dependendo do contexto em que é utilizada. Por exemplo, a palavra “banco” pode se referir a uma instituição financeira ou a um assento, e o PLN deve ser capaz de distinguir entre esses significados. Para resolver esse tipo de desafio, técnicas como o word embedding, que transforma palavras em vetores de números de alta dimensão, são amplamente utilizadas para capturar a relação semântica entre palavras em diferentes contextos.

A Figura 4 representa exemplo de pré-processamento textual em PLN, onde a palavra "Computadores" passa pela etapa de radicalização (stemming), resultando na forma base "Computador" ou na raiz "Comput".

Figura 4-Redução de Palavras no PLN.



Fonte: Autores. (2025)

3.5 Análise de sentimentos

A análise de sentimentos é uma técnica que combina o Processamento de Linguagem Natural (PLN), a linguística computacional e algoritmos de aprendizado de máquina para identificar o tom emocional presente em textos digitais. Por meio dessa abordagem, é possível classificar expressões como positivas, negativas ou neutras, o que permite às organizações obter insights valiosos sobre a percepção de clientes em relação a marcas, produtos, serviços ou ideias. Essas informações contribuem significativamente para a compreensão do comportamento do consumidor e para a tomada de decisões estratégicas. (ELASTIC, 2023)

Apesar do rápido progresso das tecnologias voltadas à análise de sentimentos, este campo ainda é relativamente recente. Segundo Liu Bing (2020), em Análise de Sentimento, o termo só se popularizou a partir de 2003. Contudo, desafios e aspectos a serem compreendidos e aperfeiçoados ainda persistem. As principais limitações e dificuldades desta área são apresentadas a seguir. (IBM, 2023)

- **Falta de contexto:** O contexto é essencial para interpretar corretamente as emoções expressas em um texto, sendo um dos principais fatores de erro em ferramentas de análise de sentimentos. Em pesquisas de satisfação, por exemplo, a mesma palavra pode indicar uma opinião positiva ou negativa dependendo da pergunta feita. Termos como "funcionalidade" ou "UX" podem ser avaliados de forma oposta conforme o

enunciado. Para lidar com essa ambiguidade, é necessário considerar o contexto da pergunta original, o que exige técnicas de pré ou pós-processamento, geralmente complexas e demoradas.

- **Uso de ironia e sarcasmo:** Mesmo com treinamentos avançados, os sistemas de análise de sentimentos ainda enfrentam dificuldades em reconhecer ironia e sarcasmo. Isso ocorre porque esses recursos linguísticos são geralmente transmitidos por tom de voz ou expressões faciais, não sendo facilmente detectáveis apenas pelo texto. Frases como “Tô morrendo de fome” podem ser interpretadas de forma incorreta, apesar da clara conotação negativa.
- **Negação:** A negação representa um desafio comum na análise de sentimentos, pois altera o significado original de uma frase ao inverter seu tom. Por exemplo, na frase “Eu não diria que estou tão triste hoje”, o sentido implícito é que está triste mas não tão triste. No entanto, algoritmos de análise de sentimentos muitas vezes não captam essa sutileza, interpretando errado a afirmação como positiva.

4. METODOLOGIA

A pesquisa exploratória busca oferecer uma compreensão inicial do problema, tornando-o mais claro ou auxiliando na formulação de hipóteses. Seu principal propósito é o desenvolvimento de ideias ou a identificação de novas percepções. Para isso, seu planejamento é flexível, permitindo a análise de diferentes aspectos relacionados ao fenômeno estudado (GIL, 2017).

O presente trabalho tem como objetivo desenvolver uma plataforma com um chatbot capaz de realizar a análise das emoções dos usuários por meio de interações em linguagem natural.

A metodologia adotada neste trabalho foi estruturada em cinco fases principais:

1. Pesquisa e seleção de ferramentas: Esta etapa contempla o levantamento e análise de bibliografia e soluções tecnológicas já existentes, com foco na identificação das ferramentas mais adequadas para a construção do chatbot e para a análise emocional.
2. Configuração do ambiente: Nesta etapa, realiza-se a preparação do ambiente de desenvolvimento, incluindo a instalação e configuração das ferramentas selecionadas, definição da arquitetura da plataforma e organização dos recursos necessários para o desenvolvimento da aplicação.
3. Elaboração do back-end: Fase dedicada à implementação da lógica do chatbot, incluindo o processamento das mensagens dos usuários, integração com os serviços de análise emocional e definição do fluxo de conversação. Também engloba a estruturação da API e a comunicação entre os módulos internos da aplicação.
4. Desenvolvimento do front-end: Refere-se à criação da interface gráfica da plataforma, responsável por viabilizar a interação entre o usuário e o chatbot.
5. Validação e integração: Etapa dedicada aos testes de funcionamento do chatbot e à validação da eficácia da análise emocional.

A Figura 5 representa um mapa mental das quatro fases da metodologia adotada.

Figura 5-Fases da metodologia.



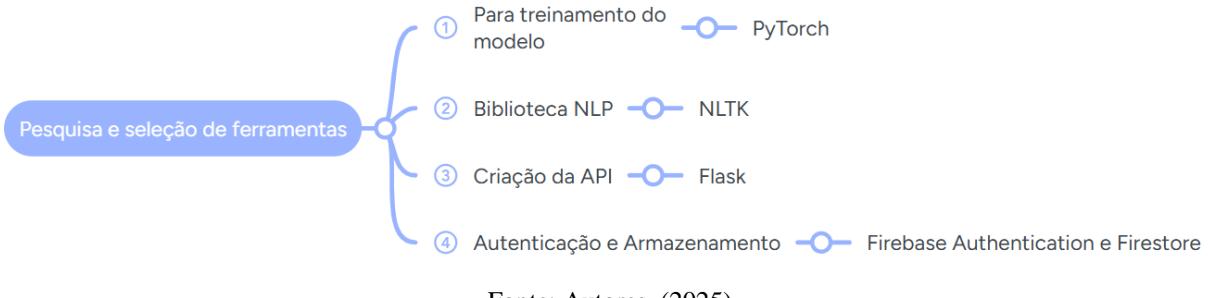
Fonte: Autores. (2025)

4.1 Pesquisa e seleção de ferramentas

Nesta etapa, foi realizada uma análise comparativa de bibliotecas, frameworks e tecnologias voltadas ao desenvolvimento de modelos de inteligência artificial e interfaces interativas. Foram considerados critérios como desempenho, compatibilidade com Python, facilidade de integração e documentação. As ferramentas selecionadas para compor a arquitetura da aplicação foram: PyTorch, NLTK, Flask e Firebase.

A Figura 6 representa um mapa mental com a organização das ferramentas selecionadas para o desenvolvimento do projeto.

Figura 6-Fase de Pesquisa e seleção de ferramentas.



Fonte: Autores. (2025)

4.1.1 PyTorch

PyTorch é uma biblioteca open-source de aprendizado de máquina para Python, desenvolvida com foco em flexibilidade e desempenho. Seu principal diferencial é o uso de grafos computacionais dinâmicos (define-by-run), que permitem construir e modificar redes neurais de forma mais intuitiva durante a execução do código. (Divanshu Singh, 2025)

A biblioteca oferece suporte a modelos recorrentes como Elman RNN, GRU e LSTM — inclusive variantes bidirecionais e com múltiplas camadas. Para casos que exigem customização, como aplicar normalização em LSTMs, PyTorch disponibiliza o TorchScript, que permite otimizações para execução eficiente em GPUs, sem exigir programação em CUDA. (The PyTorch Team, 2019)

Além disso, PyTorch oferece suporte a treinamento distribuído, integração com o ecossistema Python e recursos para implantação em produção, como o TorchServe. É compatível com diversas plataformas de nuvem e aceleradores de hardware como GPUs e TPUs. (PARRIS, 2023).

4.1.2 NLTK

NLTK (*Natural Language Toolkit*) é uma biblioteca de código aberto amplamente utilizada para tarefas de Processamento de Linguagem Natural (PLN) em Python. Desenvolvida pela Universidade da Pensilvânia, ela fornece um conjunto extenso de ferramentas voltadas à análise textual, sendo amplamente aplicada em contextos de pesquisa, ensino e prototipagem de soluções baseadas em linguagem. (NLTK, 2025)

Entre as funcionalidades oferecidas pela biblioteca, destacam-se a tokenização de textos em sentenças ou palavras, a etiquetagem gramatical que permite identificar classes como substantivos, verbos e adjetivos, e o reconhecimento de entidades nomeadas, como pessoas, locais e datas. Além disso, o NLTK possibilita a análise de sentimentos para identificar o tom emocional dos textos, a classificação de conteúdos em categorias predefinidas, a aplicação de técnicas como stemming e lematização para reduzir palavras às suas formas básicas, e também a análise sintática para compreender a estrutura gramatical das sentenças. A biblioteca oferece ainda ferramentas para estudar padrões de uso das palavras por meio da análise de colocação e concordância, além de disponibilizar acesso a diversos corpora e dicionários linguísticos, como o WordNet, o que facilita o treinamento e a avaliação de modelos linguísticos. (NLTK, 2025)

4.1.3 Flask

APIs (Application Programming Interfaces) são conjuntos de regras que permitem a comunicação entre diferentes sistemas ou aplicações. Para criar essas interfaces em Python, existem frameworks que simplificam o processo de receber, processar e responder a requisições de forma estruturada e eficiente. (RED HAT, 2020)

Flask é um microframework em Python voltado para o desenvolvimento de APIs e aplicações web. É conhecido por sua leveza, simplicidade e flexibilidade, permitindo ao desenvolvedor montar a estrutura da aplicação conforme as necessidades específicas do projeto. (ANDRADE, 2025)

O Flask facilita a criação de endpoints RESTful, integração com bancos de dados e implementação de lógica de backend para aplicações interativas. Por ser minimalista, é ideal para protótipos rápidos, com possibilidade de expansão modular. (ANDRADE, 2025)

4.1.4 Firebase

O Firebase é uma plataforma de desenvolvimento Backend-as-a-Service (BaaS) criada pelo Google, que oferece uma variedade de ferramentas voltadas à criação de aplicações modernas, tanto web quanto mobile. Entre seus principais recursos estão banco de dados em

tempo real, autenticação de usuários, hospedagem, notificações push, analytics, entre outros. Seu funcionamento em nuvem elimina a necessidade de manutenção de servidores próprios, oferecendo infraestrutura escalável, segura e com suporte a diversas linguagens de programação. O Firebase é baseado em princípios como simplicidade na integração, atualização em tempo real dos dados e foco na experiência do desenvolvedor, o que o torna uma solução amplamente adotada em projetos de diferentes portes. (ANDRE RIBEIRO, 2023)

O Firebase Authentication é o serviço de autenticação da plataforma, projetado para facilitar a verificação de identidade dos usuários de uma aplicação. Ele permite implementar, de forma rápida e segura, sistemas de login utilizando métodos tradicionais como e-mail e senha, além de oferecer suporte a provedores externos, como Google, Facebook, Twitter e GitHub. Esse serviço também disponibiliza bibliotecas e interfaces prontas para uso, o que reduz significativamente a complexidade da implementação e melhora a experiência do usuário final. Ao garantir que apenas usuários autenticados tenham acesso a determinadas funcionalidades ou dados, o Authentication contribui diretamente para a segurança e integridade das aplicações. (ANDRE RIBEIRO, 2023)

O Cloud Firestore é o banco de dados NoSQL do Firebase, projetado para armazenar, sincronizar e consultar dados de forma eficiente em tempo real. Diferentemente dos bancos relacionais, o Firestore organiza a informação em documentos e coleções, o que proporciona maior flexibilidade no tratamento de dados não estruturados. Ele permite a execução de consultas complexas, possui suporte a sincronização em tempo real e funcionamento offline, e foi desenvolvido para escalar automaticamente conforme o crescimento da aplicação. Suas capacidades de resposta rápida e atualização simultânea o tornam ideal para sistemas interativos que exigem consistência de dados entre múltiplos usuários e dispositivos. (ANDRE RIBEIRO, 2023)

Neste trabalho, o Firebase foi utilizado para a autenticação de usuários e o armazenamento das mensagens trocadas com o chatbot, além dos dados dos próprios usuários. A escolha do Firebase viabilizou uma infraestrutura robusta e de fácil integração com as demais tecnologias.

4.2 Configuração do Ambiente

A configuração do ambiente de desenvolvimento envolve dois aspectos principais: a instalação das bibliotecas e dependências necessárias, bem como a preparação do conjunto de dados utilizado para o treinamento do modelo de análise emocional.

Inicialmente, foi realizada a instalação das bibliotecas essenciais para o desenvolvimento da aplicação. O projeto foi implementado em Python 3.12, utilizando um ambiente virtual para garantir a organização e a reproduzibilidade do processo. As principais bibliotecas utilizadas incluem: PyTorch, para construção e treinamento do modelo de aprendizado profundo; NLTK (Natural Language Toolkit), para o pré-processamento textual, como tokenização e remoção de stopwords; Flask, para a criação da API REST responsável pela comunicação entre o modelo e a interface da plataforma; e NumPy, para manipulação de dados. A instalação dessas dependências foi realizada por meio do gerenciador de pacotes pip.

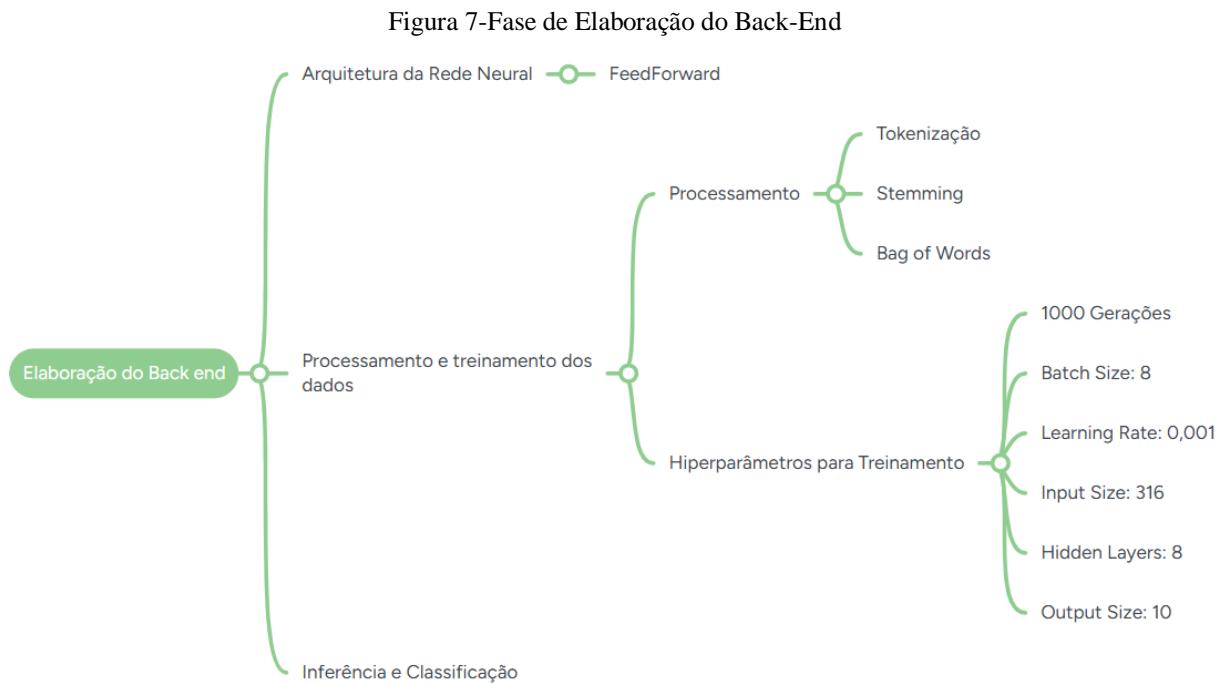
Na etapa de preparação dos dados, foi utilizado um conjunto de mensagens textuais previamente rotuladas com emoções como “ansiedade”, “tristeza”, “neutro” e “positivo”. Esse dataset passou por um processo de normalização e pré-processamento, que envolveu: remoção de pontuação e caracteres especiais, conversão das palavras para minúsculas, tokenização das frases, remoção de stopwords com a biblioteca NLTK e transformação das frases em vetores numéricos (embeddings), adequados como entrada para o modelo. Além disso, quando necessário, foram aplicadas técnicas de data augmentation, com o objetivo de balancear a distribuição entre as classes e melhorar o desempenho geral do modelo.

4.3 Elaboração do Back-End

Esta etapa consiste na construção da rede neural responsável pela identificação das intenções presentes nas mensagens dos usuários. Inclui o pré-processamento dos dados, o treinamento do modelo com base nesses dados e a aplicação do modelo treinado para classificar novas mensagens durante a interação. Dessa forma, o sistema realiza a interpretação das entradas textuais, convertendo-as em respostas adequadas conforme a intenção detectada.

A Figura 6 representa um Mapa mental que ilustra os principais componentes da elaboração do back-end, abrangendo a arquitetura da rede neural, o processamento dos dados,

o treinamento do modelo e o processo de inferência para classificação das intenções dos usuários.



Fonte: Autores. (2025)

4.3.1 Arquitetura da Rede Neural

A rede neural implementada neste trabalho é do tipo feedforward e foi projetada com três camadas lineares. A camada de entrada recebe vetores no formato bag of words, cuja dimensão corresponde ao número de palavras únicas extraídas dos padrões de entrada, convertendo o texto em uma representação numérica comprehensível pela rede.

O processamento subsequente ocorre em duas camadas ocultas, cada uma composta por oito neurônios que utilizam a função de ativação ReLU (Rectified Linear Unit). Essa função é fundamental para a rede, pois introduz uma não linearidade que permite aprender representações intermediárias dos dados. A ReLU funciona retornando o valor da entrada quando este é positivo e zero quando é negativo, o que significa que apenas alguns neurônios são ativados a cada instante, tornando a rede mais eficiente e facilitando o aprendizado de padrões complexos. (Data Science Academy, 2025)

Por fim, a camada de saída contém um número de neurônios igual ao número de intenções (ou tags) que o modelo pode identificar. Durante a inferência, os valores dessa camada passam por uma função softmax, que converte as saídas em probabilidades associadas a cada classe, possibilitando a classificação da intenção expressa pelo usuário.

4.3.2 Processamento, Treinamento e Inferência do Modelo

Os dados utilizados foram organizados no formato JSON, contendo intents, que agrupam padrões de frases (patterns) e respostas (responses) correspondentes. Para o pré-processamento das entradas, as frases passaram por tokenização e normalização com stemming, visando reduzir as variações morfológicas e facilitar a análise. Em seguida, aplicou-se a técnica de bag of words para converter os textos em vetores numéricos que representassem as ocorrências de palavras no vocabulário. As intenções foram então convertidas em índices inteiros para que pudessem ser usadas como rótulos durante o treinamento do modelo.

O processo de treinamento envolveu o uso da função de perda *CrossEntropyLoss* e do otimizador Adam, com hiperparâmetros configurados para 1000 épocas, *batch size* igual a 8 e taxa de aprendizado de 0.001. Durante o treinamento, o valor da função de perda apresentou uma redução significativa, iniciando em aproximadamente 0,0125 na época 100 e decrescendo até valores próximos de zero a partir da época 500, mantendo-se estável até a conclusão do treinamento na época 1000, quando o valor final da perda foi praticamente zero. Essa redução constante da função de perda indica que o modelo conseguiu ajustar seus pesos de forma eficaz para minimizar os erros na classificação das intenções, melhorando a capacidade preditiva do chatbot.

Após o término do treinamento, o modelo foi salvo e carregado para uso na aplicação web desenvolvida em Flask. No momento em que o usuário envia uma mensagem, esta é novamente processada pelo *pipeline* de tokenização e transformação em vetor *bag of words*. O vetor resultante é então passado pela rede neural para calcular as probabilidades associadas a cada intenção prevista. Caso a maior probabilidade ultrapasse um limiar definido em 0,75, o chatbot retorna a resposta correspondente à intenção identificada. Se a probabilidade máxima for inferior a esse limiar, o sistema sinaliza que não entendeu a mensagem, garantindo assim maior segurança e precisão na comunicação. Essa abordagem possibilita ao chatbot reconhecer

múltiplas intenções com base em probabilidades, mantendo a flexibilidade e robustez necessárias para uma interação natural e eficaz com o usuário.

4.4 Desenvolvimento da plataforma

A plataforma web foi desenvolvida com o objetivo de proporcionar uma interação eficiente e intuitiva entre o usuário e o chatbot, integrando uma interface clara e dinâmica ao back-end. Para isso, foram utilizadas tecnologias web padrão como HTML, CSS e JavaScript. O sistema inclui funcionalidades essenciais como autenticação de usuários, gerenciamento de conversas, troca de mensagens em tempo real e integração com profissionais da área de psicologia, sendo o Firebase utilizado para autenticação (Firebase Authentication) e armazenamento de dados (Firestore).

A interface foi estruturada em diferentes seções, abrangendo a tela de login e cadastro, a área principal de conversação, os campos destinados à entrada de mensagens e os botões funcionais. A escolha da paleta de cores, composta por tons suaves de verde, foi pensada para promover uma atmosfera de tranquilidade e conforto durante a interação do usuário com a plataforma.

Para garantir a interatividade, o comportamento dinâmico da plataforma foi implementado utilizando JavaScript puro. Entre as funcionalidades estão a manipulação do DOM para a exibição em tempo real das mensagens enviadas pelo usuário e pelo chatbot, o uso da API fetch com `async/await` para o envio de requisições HTTP ao back-end desenvolvido em Flask, que processa as mensagens e retorna as respostas geradas pelo modelo. Além disso, o sistema controla eventos para o envio das mensagens tanto pelo clique em botões quanto pela tecla Enter, e realiza a geração dinâmica de novos elementos no chat a cada troca de mensagens, garantindo uma experiência fluida e responsiva ao usuário.

4.4.1 Funcionalidades e Integração com Firebase

A plataforma foi desenvolvida integrando o Firebase para gerenciar funcionalidades essenciais no backend do cliente. Para autenticação de usuários, foi utilizado o módulo Firebase

Authentication, que permite o cadastro, login e logout por meio de e-mail e senha, assegurando a segurança no acesso. Além disso, o banco de dados Firestore foi empregado para armazenar informações dos usuários, incluindo o histórico das conversas, as mensagens trocadas em tempo real e os dados coletados por meio do formulário de agendamento de consultas.

As regras de segurança do Firebase foram configuradas cuidadosamente para garantir que cada usuário tenha acesso restrito aos seus próprios dados, protegendo a privacidade e evitando acessos não autorizados. Com essa estrutura, a plataforma oferece funcionalidades robustas, como a criação e organização de novos chats, que são armazenados separadamente para manter o histórico de forma organizada. A troca de mensagens ocorre em tempo real, com persistência automática no banco de dados, o que permite que as conversas sejam mantidas atualizadas e acessíveis a qualquer momento.

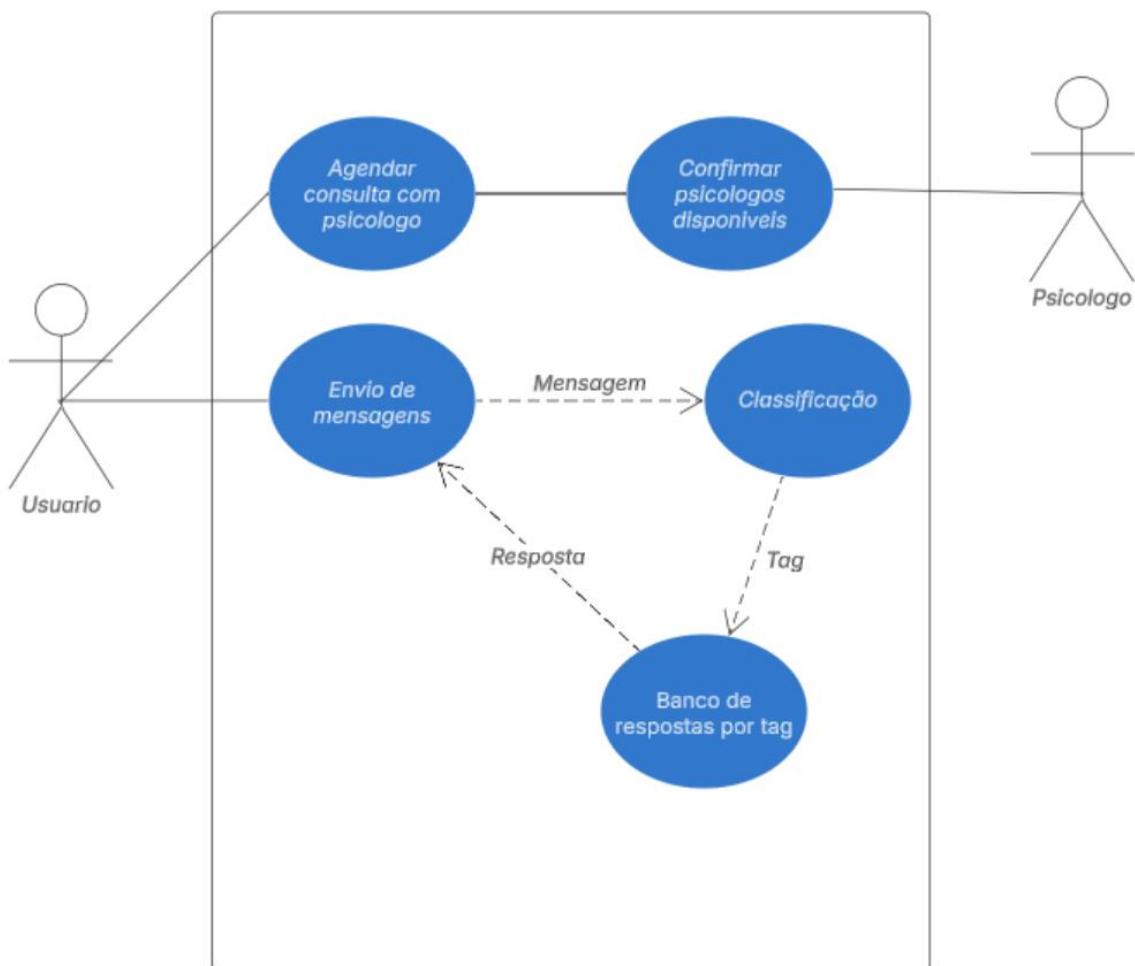
Além disso, a plataforma disponibiliza um sistema de agendamento de consultas com psicólogos parceiros, no qual o usuário preenche um formulário que é enviado diretamente aos profissionais, facilitando a comunicação e o gerenciamento das consultas. O histórico de conversas permanece acessível e é atualizado constantemente a cada interação, garantindo que o usuário tenha acesso completo às informações das sessões anteriores.

4.4.2 Modelagem do Sistema

Esta seção apresenta a modelagem do sistema desenvolvida para representar visualmente sua estrutura e funcionalidades. Por meio de diagramas, busca-se facilitar a compreensão da organização e do comportamento da plataforma, apoiando a documentação técnica do projeto.

A Figura 8 apresenta o diagrama de casos de uso do sistema, ilustrando as principais interações entre o usuário e a plataforma. Destacam-se, entre os casos de uso, o agendamento de consulta com um profissional, no qual o usuário preenche um formulário que é encaminhado aos psicólogos parceiros para posterior contato, e a troca de mensagens com o chatbot, onde o usuário envia mensagens e recebe respostas automáticas baseadas na análise das intenções identificadas pelo modelo.

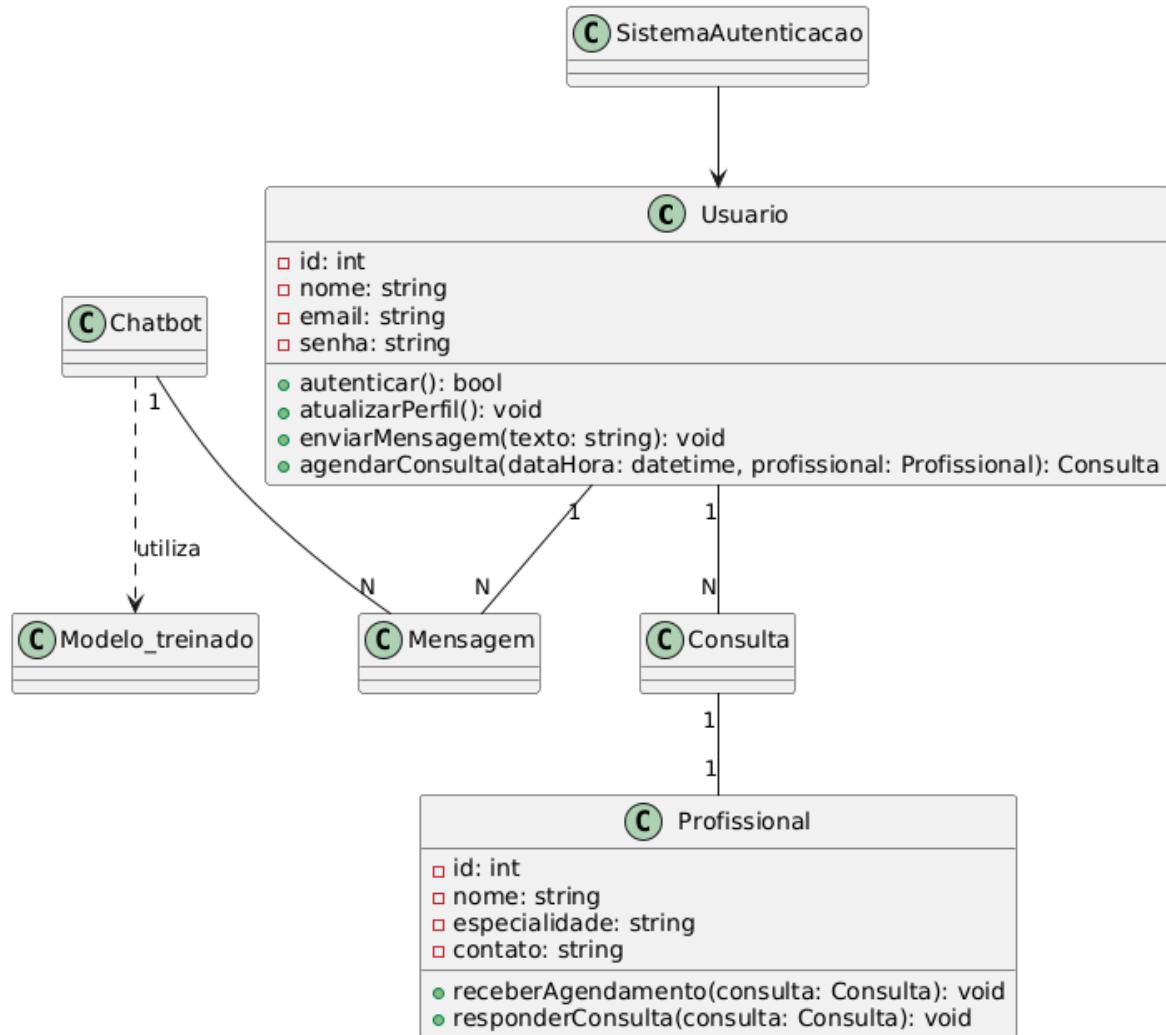
Figura 8-Diagrama de Casos de Uso



Fonte: Autores. (2025)

A Figura 9 apresenta o diagrama de classes da plataforma. O diagrama ilustra as principais classes envolvidas, seus atributos e métodos, bem como os relacionamentos entre elas. São destacadas as classes referentes ao usuário, profissional, chatbot, mensagens, consultas e sistema de autenticação, evidenciando como os componentes do software interagem para suportar as funcionalidades de autenticação, troca de mensagens, agendamento de consultas e processamento das interações via inteligência artificial.

Figura 9-Diagrama de Classes



Fonte: Autores. (2025)

4.7 Validação e Integração na Plataforma

A validação do algoritmo teve como objetivo avaliar tanto a precisão da classificação das intenções quanto a adequação das respostas geradas pelo chatbot.

Além disso, a integração do modelo treinado em uma plataforma web foi implementada para garantir a interação fluida e responsiva com os usuários, permitindo o uso prático do sistema em ambiente real.

4.7.1 Validação Técnica

Durante o treinamento, foi monitorada a função de perda (loss) ao longo das épocas, observando-se sua diminuição progressiva. Esse comportamento indicou que o modelo estava aprendendo a classificar corretamente os padrões de entrada.

Além disso, o modelo retorna as três intenções mais prováveis para cada entrada, com suas respectivas probabilidades. Essa abordagem possibilitou:

- Avaliar se a intenção com maior probabilidade correspondia à resposta esperada;
- Identificar casos de ambiguidade, com múltiplas intenções com confiança alta;
- Aplicar um limiar de confiança de 0.75 para filtrar classificações incertas.

4.7.2 Validação Funcional

A aplicação foi testada com um conjunto diverso de frases simulando diálogos naturais com usuários. Foram avaliados critérios como:

- Coerência e clareza das respostas fornecidas;
- Capacidade de generalização, reconhecendo variações linguísticas não presentes diretamente no treinamento;
- Respostas apropriadas diante de entradas incomuns ou fora de contexto.

Nos casos em que o modelo detectava mais de uma intenção com alta probabilidade, o sistema adotava uma abordagem preventiva, solicitando ao usuário que focasse em apenas um assunto por vez, a fim de evitar confusão interpretativa.

4.7.3 Integração na Plataforma

O modelo treinado foi incorporado em uma plataforma web baseada em Flask, que possibilita a comunicação em tempo real entre o usuário e o chatbot. Essa integração incluiu:

Um endpoint REST para receber mensagens do usuário e enviar respostas geradas pelo modelo;

Processamento das mensagens com pré-processamento textual (tokenização, vetorização);

Implementação de regras para tratamento de múltiplas intenções e controle da experiência do usuário;

Essa arquitetura integrada permite que o chatbot funcione de forma responsiva e escalável, facilitando sua aplicação prática em contextos reais de atendimento e suporte psicológico.

4.7.4 Análise de Requisitos

A análise de requisitos é uma etapa fundamental no processo de desenvolvimento. Nesta fase, são identificadas as funcionalidades e as características técnicas necessárias para que o sistema atenda adequadamente às necessidades dos usuários, que incluem tanto pacientes quanto profissionais da saúde mental.

Para garantir a eficácia da solução proposta, os requisitos foram classificados em funcionais e não funcionais:

Requisitos Funcionais:

- Cadastro de Pacientes;
- Cadastro de Psicólogos;
- Envio e Classificação de Mensagens;
- Respostas Automáticas;
- Histórico de Interações;
- Controle de Acesso.

Requisitos Não Funcionais:

- Segurança e Privacidade nas informações sensíveis dos usuários;
- Tempo de resposta otimizado para ações comuns do sistema.
- Interface intuitiva e de fácil navegação
- Assegurar a integridade dos dados, evitando perda ou corrupção de informações
- Compatibilidade com os principais navegadores

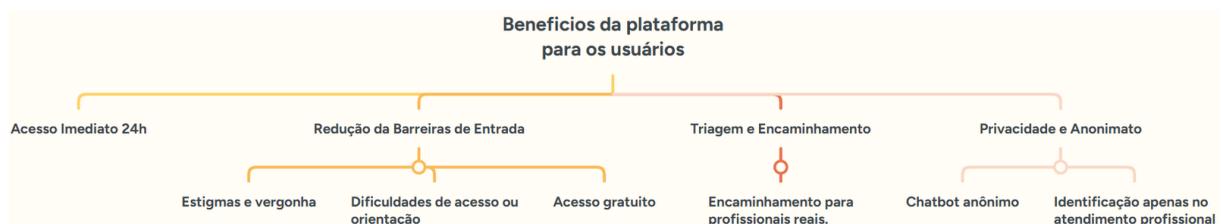
5. RESULTADOS E DISCUSSÕES

A seguir, são apresentados os resultados obtidos com base na plataforma em funcionamento.

A solução busca oferecer suporte inicial ao bem-estar emocional dos usuários, com respostas adequadas ao contexto de suas mensagens e um atendimento mais humanizado.

A plataforma proposta oferece diversos benefícios aos usuários, com destaque para o acesso imediato e contínuo, disponível 24 horas por dia. Esse suporte constante contribui para a redução de barreiras comuns ao cuidado psicológico, como o estigma, a vergonha e a falta de orientação adequada. Além disso, o serviço é gratuito, ampliando ainda mais o alcance do suporte oferecido. Para aqueles que optarem por um atendimento com um profissional da área, a plataforma realiza o encaminhamento de forma facilitada. Durante a interação com o chatbot, a privacidade e o anonimato dos usuários são preservados, sendo necessário fornecer identificação apenas nos casos em que houver interesse no atendimento humano, garantindo segurança e conforto durante todo o processo. Essas funcionalidades e fluxos de interação estão representados na Figura 10, que ilustra os benefícios da plataforma.

Figura 10-Benefícios da plataforma



Fonte: Autores. (2025)

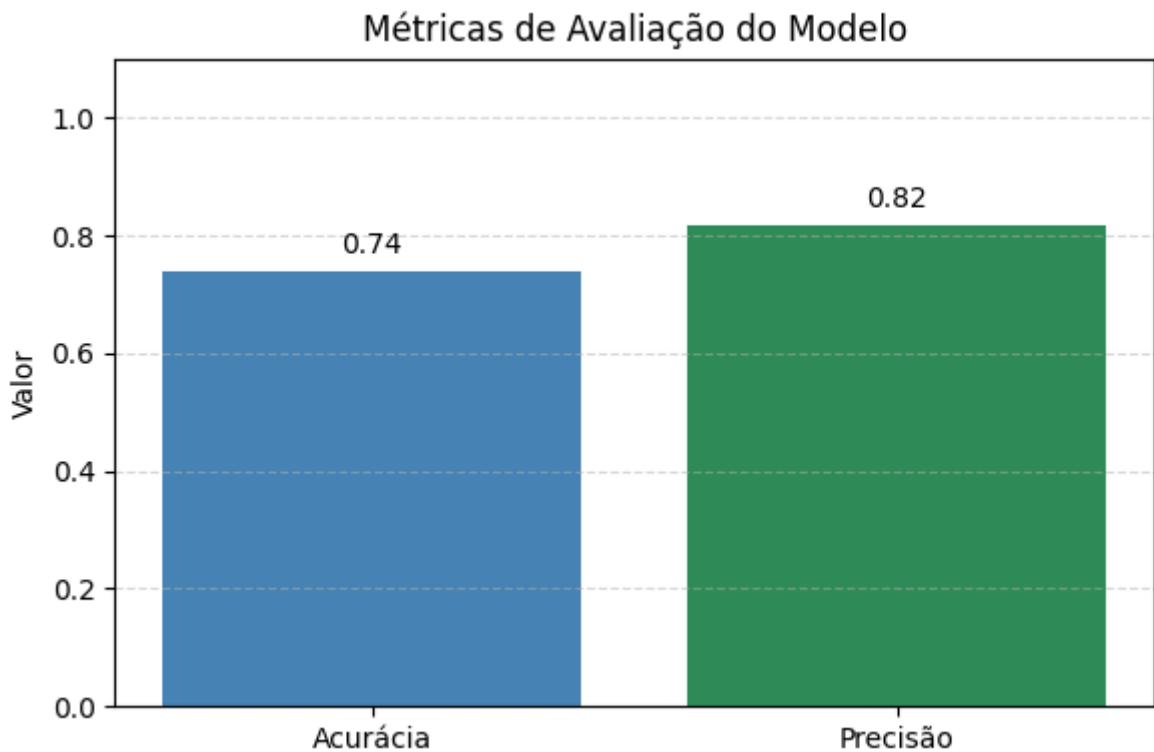
5.1 Avaliação do Modelo Treinado

Para avaliar o desempenho do modelo de classificação de intenções, foram analisados 150 casos de teste. Em 136 deles, o sistema foi capaz de identificar alguma intenção e fornecer uma resposta. Dentre essas tentativas, 111 classificações foram corretas, ou seja, a intenção atribuída correspondeu à intenção real da mensagem. Com base nesses dados, foram calculadas duas métricas: a acurácia, que representa a proporção de acertos em relação ao total de tentativas, foi de aproximadamente 0,74; e a precisão, que indica o número de acertos entre as respostas fornecidas, alcançou cerca de 0,82. Esses resultados demonstram um bom

desempenho do modelo, com alta capacidade de fornecer respostas corretas quando identifica uma intenção.

A Figura 11 mostra um gráfico ilustrando as métricas de desempenho obtidas na avaliação do modelo de classificação de intenções, com base em 150 tentativas.

Figura 11-Gráfico de Acurácia e Precisão do Modelo

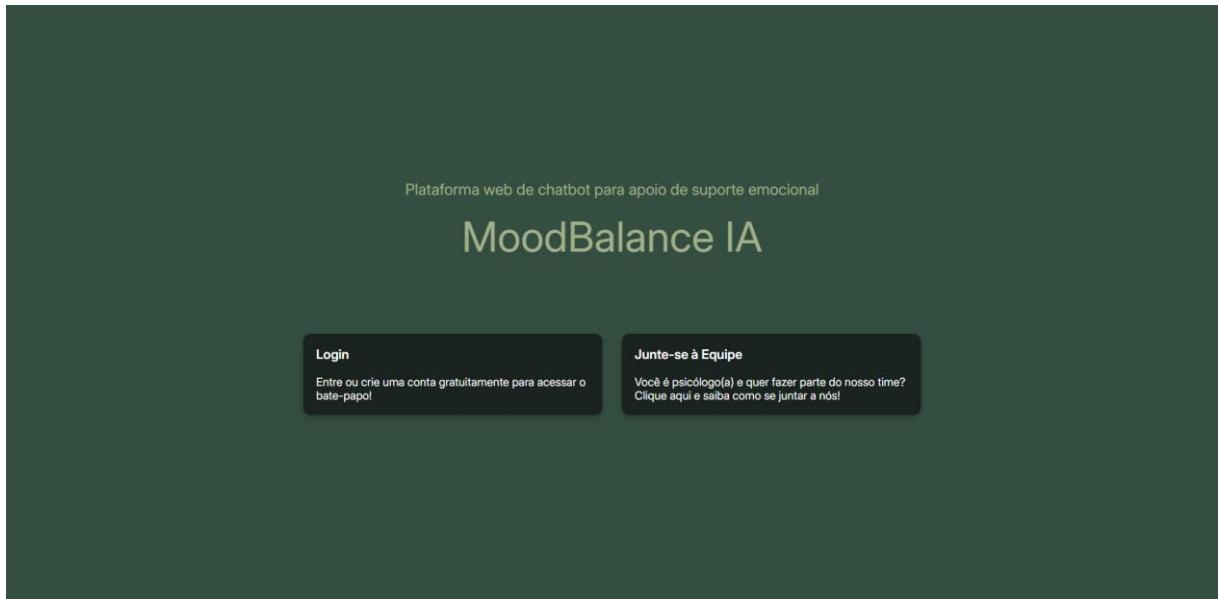


Fonte: Autores. (2025)

5.2 Apresentação da Plataforma

A Figura 12 apresenta a tela inicial da plataforma, onde o usuário pode acessar as opções de login e cadastro. O layout foi projetado para proporcionar uma navegação simples e objetiva.

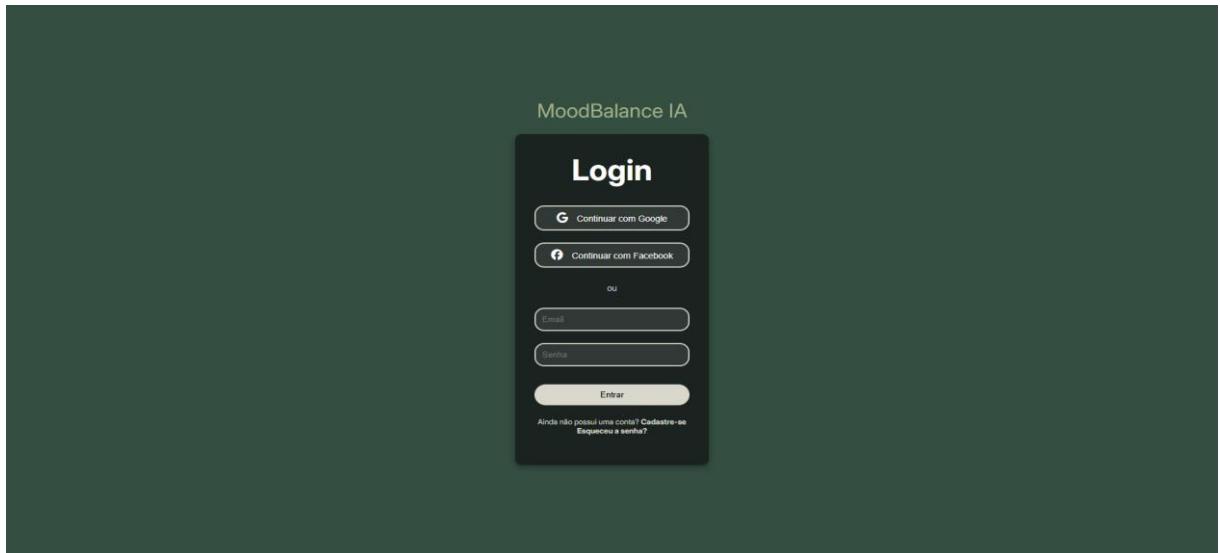
Figura 12-Tela Inicial



Fonte: Autores, 2025

A Figura 13 mostra o formulário de login, no qual o usuário insere seu e-mail e senha para autenticação. O processo é gerenciado pelo Firebase Authentication, garantindo segurança e controle de acesso.

Figura 13-Tela de Login

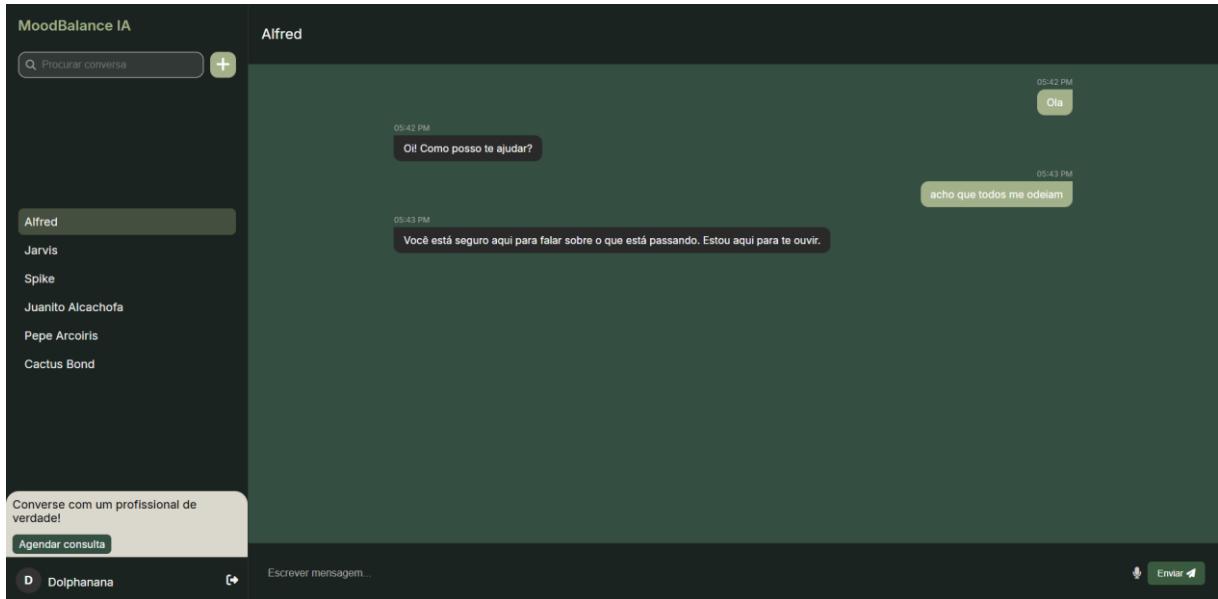


Fonte: Autores, 2025

5.3 Comportamento do Chatbot

Na Figura 14, observa-se a tela principal do chat após o login. O usuário digita uma mensagem, que é enviada para o back-end responsável pelo processamento com o modelo treinado. A resposta do chatbot é exibida automaticamente na interface.

Figura 14-Conversa com o Chat



Fonte: Autores, 2025

A Figura 15 exibe o terminal do servidor Python, no qual é possível visualizar a classificação das intenções correspondentes às mensagens recebidas. Essa etapa demonstra o funcionamento do modelo de rede neural e sua integração com a interface web. As mensagens classificadas referem-se às interações realizadas no chat da plataforma, apresentadas na Figura 14.

Figura 15-Conversa com o Chat no terminal

```

127.0.0.1 - - [14/Jun/2025 17:42:39] "OPTIONS /message HTTP/1.1" 204 -
Mensagem: Ola
Tags mais prováveis:
1. Tag: saudacao, Prob: 0.8080
2. Tag: ironia, Prob: 0.1805
3. Tag: preconceito, Prob: 0.0052
Resposta: Oi! Como posso te ajudar?
127.0.0.1 - - [14/Jun/2025 17:42:39] "POST /message HTTP/1.1" 200 -
127.0.0.1 - - [14/Jun/2025 17:43:16] "OPTIONS /message HTTP/1.1" 204 -
Mensagem: acho que todos me odeiam
Tags mais prováveis:
1. Tag: paranoia, Prob: 0.9999
2. Tag: termino, Prob: 0.0000
3. Tag: preconceito, Prob: 0.0000
Resposta: Você está seguro aqui para falar sobre o que está passando. Estou aqui para te ouvir.
127.0.0.1 - - [14/Jun/2025 17:43:16] "POST /message HTTP/1.1" 200 -

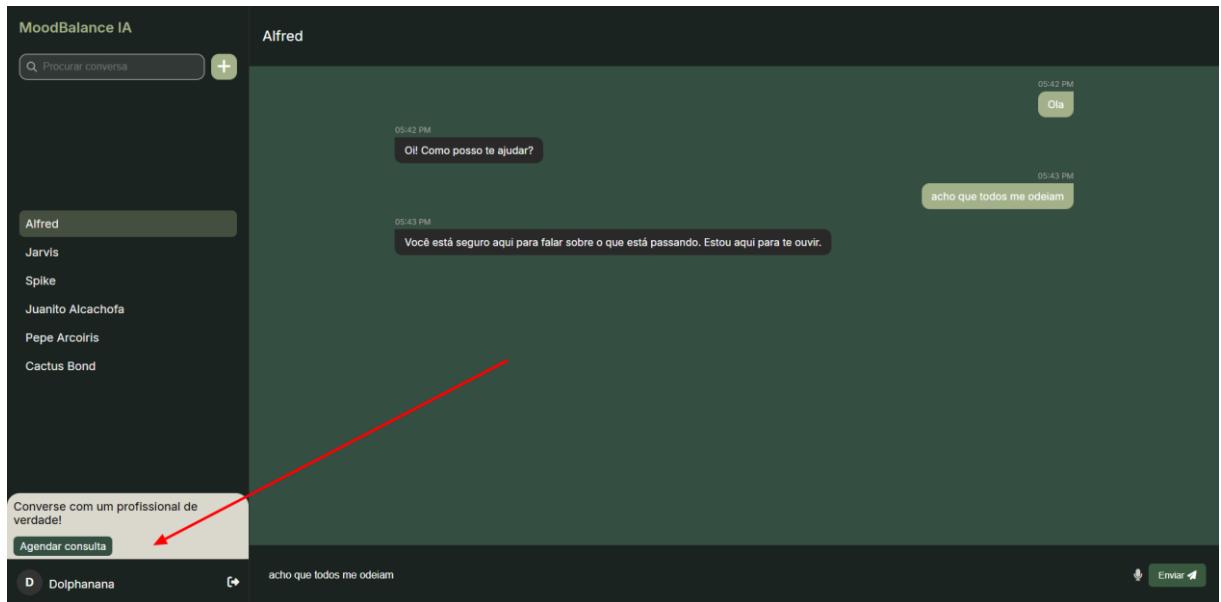
```

Fonte: Autores, 2025

5.4 Funcionalidade de Agendamento

A Figura 16 mostra o botão disponível na interface para iniciar o agendamento de uma consulta com um psicólogo parceiro. Ao ser clicado, ele exibe um formulário para preenchimento.

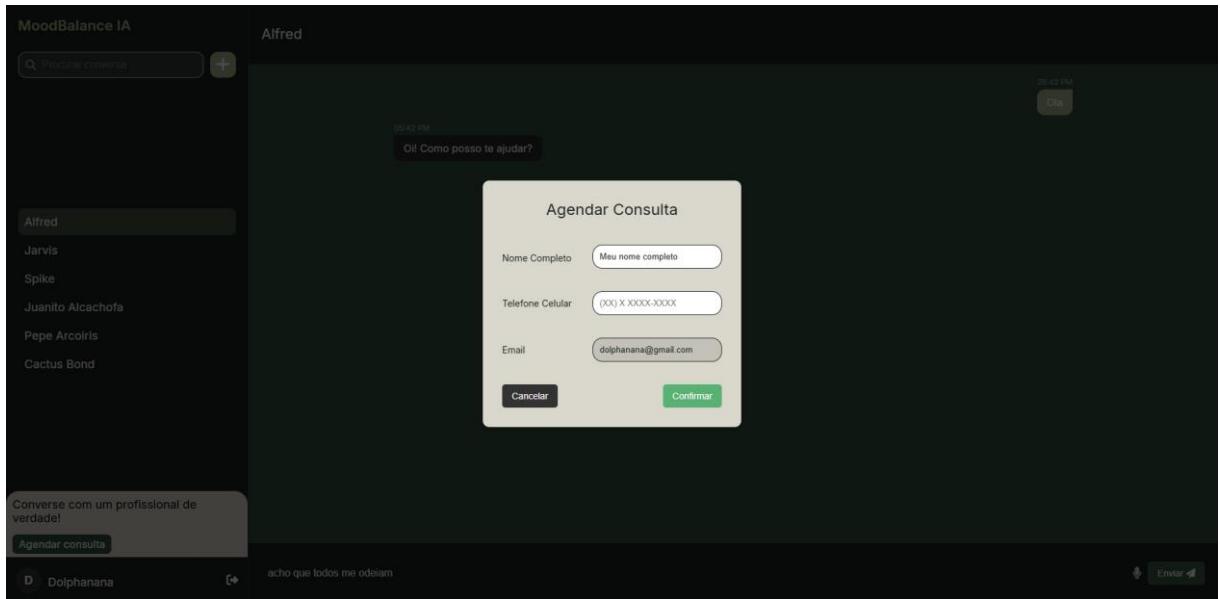
Figura 16-Botão para agendar uma consulta



Fonte: Autores, 2025

Na Figura 17, é apresentado o formulário de agendamento, onde o usuário insere dados como nome, e-mail, motivo da consulta e horário preferencial. As informações são então armazenadas no Firebase Firestore e ficam disponíveis para a equipe responsável pelo atendimento.

Figura 17-Confirmação de agendamento de consulta



Fonte: Autores, 2025

5.5 Dificuldades Encontradas

Durante o desenvolvimento do projeto, algumas dificuldades técnicas e conceituais foram enfrentadas. Uma das principais limitações esteve relacionada ao processo de classificação de intenções pelo modelo de IA, especialmente em mensagens com tons de ironia ou linguagem informal. Expressões como "estou morrendo de fome", embora comuns no cotidiano, foram interpretadas literalmente pelo modelo, o que comprometeu a precisão da classificação em determinados contextos. Esse desafio evidencia a complexidade da linguagem natural e a necessidade de datasets mais robustos e diversificados.

Outro obstáculo importante foi o tamanho reduzido do conjunto de dados de treinamento. Como o modelo foi treinado com base em exemplos definidos manualmente no arquivo intents.json, a quantidade limitada de frases dificultou o aprendizado mais profundo e a generalização da rede neural. Apesar disso, com ajustes e testes sucessivos, foi possível alcançar um desempenho funcional dentro do escopo do projeto.

5.6 Reflexão sobre os Resultados

De modo geral, os resultados obtidos foram satisfatórios em relação aos objetivos propostos. A plataforma foi concluída com sucesso, apresentando todas as funcionalidades planejadas: autenticação de usuários, interface para conversação, agendamento de consultas e armazenamento de dados no Firestore. A integração entre os módulos front-end, back-end e banco de dados demonstrou ser eficiente e estável.

Embora tenham sido identificadas limitações no reconhecimento de linguagem mais subjetiva por parte do chatbot, o sistema se mostrou eficaz na identificação das intenções previstas no conjunto de treinamento. Além disso, a funcionalidade de agendamento operou corretamente, com os dados sendo registrados no banco de forma estruturada, validando a proposta de oferecer suporte psicológico a partir da triagem automatizada.

A experiência também proporcionou um aprendizado relevante sobre os desafios da construção de sistemas de IA conversacionais e reforçou a importância de bases de dados amplas e variadas para melhorar a capacidade de interpretação do modelo. O projeto final representa, portanto, uma base sólida para futuras evoluções e melhorias.

5.7 Comparação com Soluções Existentes

PsiVirtual

É um projeto inovador de chatbot terapêutico, liderado por um professor da UFAM, que visa ser um pioneiro na utilização de IA para fins psicoterapêuticos no contexto brasileiro. Trata-se de um chatbot terapêutico que emprega inteligência artificial para oferecer suporte psicológico aos usuários. Desenvolvido para atuar como um facilitador no processo terapêutico, o sistema integra os princípios da Terapia Cognitivo-Comportamental (TCC), uma abordagem amplamente reconhecida por sua eficácia no tratamento de ansiedade, depressão e estresse.(UFAM, 2024)

Sua principal função é atuar como um facilitador no processo terapêutico, guiando o usuário por meio de um processo reflexivo e estruturado. Para isso, ele faz perguntas, fornece feedback e auxilia na identificação de padrões de pensamento disfuncionais. Além disso, a ferramenta propõe exercícios destinados a promover a reestruturação cognitiva e a adoção de estratégias de enfrentamento mais saudáveis. O sistema segue uma lógica mais orientada por protocolos clínicos e assume uma abordagem terapêutica formal, mesmo sem substituir o psicólogo. (UFAM, 2024)

Em contraposição, a plataforma proposta neste trabalho adota uma abordagem mais aberta e flexível, centrada na identificação de intenções e emoções a partir de mensagens espontâneas dos usuários. O foco está no acolhimento inicial e no encaminhamento, quando necessário, para profissionais da área. Atua como um ponto de apoio emocional, mantendo o anonimato e respeitando os limites éticos da atuação digital, apresentando um diferencial ao

enfatizar a acessibilidade, a adaptabilidade conversacional e o foco em ser uma ferramenta complementar para triagem e apoio emocional.

6. CONCLUSÕES

Portanto, com base nas obras consultadas durante a elaboração deste trabalho, evidencia-se o potencial transformador do uso de inteligência artificial no contexto da saúde mental. A combinação entre tecnologias inteligentes e práticas de acompanhamento psicológico pode contribuir significativamente para a identificação precoce de situações de risco e para a promoção do cuidado emocional.

O trabalho desenvolvido atendeu aos objetivos propostos, ao oferecer uma plataforma capaz de interpretar mensagens de usuários, responder de forma contextualizada e conectar essas interações a ações reais, como o encaminhamento para psicólogos parceiros. O modelo de rede neural, apesar de limitado pela quantidade de dados disponíveis, demonstrou desempenho funcional em situações mais objetivas, representando um passo importante na integração entre IA e suporte emocional.

Durante o desenvolvimento deste trabalho, algumas dificuldades foram enfrentadas, especialmente no que diz respeito à validação profissional da plataforma. Devido a conflitos de agenda e limitações de disponibilidade, não foi possível realizar o acompanhamento direto com a coordenação do curso de psicologia para a validação técnica e clínica do sistema. Apesar disso, buscou-se minimizar esse impacto por meio da fundamentação teórica e dos testes funcionais realizados, ressaltando a importância de futuras validações com profissionais especializados para o aprimoramento da ferramenta.

Além da construção técnica, este projeto também buscou destacar a importância do acolhimento psicológico, utilizando a tecnologia não como substituta, mas como aliada dos profissionais da área. A aplicação desenvolvida reforça essa visão, funcionando como um ponto de contato inicial que pode evoluir para um atendimento humano e personalizado.

Dessa forma, os resultados obtidos são satisfatórios dentro do escopo definido, e a plataforma desenvolvida pode ser considerada um protótipo promissor para soluções mais amplas e robustas. Espera-se que este trabalho sirva de base para futuras pesquisas e inspire o desenvolvimento de ferramentas tecnológicas voltadas ao cuidado com a saúde mental.

7. SUGESTÕES PARA TRABALHOS FUTUROS

Como continuidade deste projeto, algumas melhorias e expansões podem ser realizadas para tornar a plataforma mais robusta, precisa e acessível. Uma das principais sugestões é a ampliação do conjunto de dados utilizado no treinamento do modelo, com inclusão de mensagens mais diversas, expressões informais, ironias e variações de linguagem, a fim de aumentar a capacidade do algoritmo de interpretar contextos mais complexos.

Outra proposta é a substituição ou complementação da abordagem baseada em bag of words por modelos mais avançados de processamento de linguagem natural, como embeddings pré-treinados (ex: Word2Vec, GloVe) ou mesmo modelos baseados em transformers, como BERT, o que pode melhorar significativamente a precisão e sensibilidade do chatbot.

Do ponto de vista da interface, recomenda-se a adaptação da plataforma para dispositivos móveis, promovendo maior acessibilidade e usabilidade. Além disso, podem ser implementadas funcionalidades complementares, como acompanhamento contínuo de humor, relatórios periódicos para o usuário, e áreas exclusivas para profissionais acessarem os dados de seus pacientes (com devidas permissões e privacidade).

Por fim, também é possível explorar a integração com APIs externas de saúde mental, ou com serviços de emergência, para ampliar o alcance e impacto social da aplicação.

REFERÊNCIAS

A. M. TURING, I.—COMPUTING MACHINERY AND INTELLIGENCE, *Mind*, Volume LIX, Issue 236, October 1950, Pages 433–460, <https://doi.org/10.1093/mind/LIX.236.433>

ALCÂNTARA Santana, Robson. (2010). **Roteamento em Redes Ópticas Transparentes Utilizando Redes Neurais de Hopfield.**[SI]. (figura neuronio)

AI-QAHTANI, A.H., Al-Baltah, I.A., & Ghaleb, M. (2024). **Comparative Analysis of Deep Learning Techniques for Chatbots Implementation.** 2024 1st International Conference on Emerging Technologies for Dependable Internet of Things (ICETI), 1-10.

ANDRADE; Ana Paula, **O que é Flask?**. Disponível em: <https://www.treinaweb.com.br/blog/o-que-e-flask>. Acesso em: 14 jun. 2025

ANDRE RIBEIRO, **O que é Firebase? Para que serve, principais características e um Guia dessa ferramenta Google.** Disponível em: <https://alura.com.br/artigos/mobile/firebase>. Jun de 2023. Acesso em: 21 jun. 2025

ARAMINTA, A.S., Reynaldi, R., Qomariyah, N.N., & Sukotjo, C. (2024). **Exploring AI-Driven Chatbots for Enhanced Learning Experiences in Dental Education with Deep Learning.** 2024 International Conference on Information Management and Technology (ICIMTech), 71-76.

BROOKS, S. K., WEBSTER, R. K., SMITH, L. E., WOODLAND, L., WESSELY, S., GREENBERG, N., & RUBIN, G. J. (2020). **The psychological impact of quarantine and how to reduce it: rapid review of the evidence.** *The Lancet*, 395(10227), 912-920. [https://doi.org/10.1016/S0140-6736\(20\)30460-8](https://doi.org/10.1016/S0140-6736(20)30460-8)

DATA SCIENCE ACADEMY, **Função de Ativação.** Disponível em: <https://www.deeplearningbook.com.br/funcao-de-ativacao/>. Acesso em: 20 jun. 2025

DEVLIN, J., CHANG, M.-W., LEE, K., & TOUTANOVA, K. **BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding.** arXiv preprint arXiv:1810.04805. Disponível em: <https://arxiv.org/abs/1810.04805>.

DIVANSHU Singh, **PyTorch's dynamic computation graph - Deep Learning using Python.** Disponível em: <https://noobtomaster.com/deep-learning-python/pytorch-s-dynamic-computation-graph/>. Acesso em: 14 jun. 2025

ELASTIC. **O que é a análise de sentimentos?**. Disponível em: <https://www.elastic.co/pt/what-is/sentiment-analysis>. dez 2023. Acesso em: 20 jun. 2025

EYSENBACH G. **What is e-health?**. *J Med Internet Res* 2001;3(2):e20 Disponível em: <https://www.jmir.org/2001/2/e20> Acesso em: 22 jun. 2025.

FACELI, Katti et al. **Inteligência Artificial - Uma Abordagem de Aprendizado de Máquina**. Rio de Janeiro: Grupo GEN, 2021. E-book. ISBN 9788521637509. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9788521637509/>. Acesso em: 24 out. 2023.

FITZPATRICK K, DARCY A, VIERHILE M. **Delivering Cognitive Behavior Therapy to Young Adults With Symptoms of Depression and Anxiety Using a Fully Automated Conversational Agent (Woebot): A Randomized Controlled Trial**. JMIR Ment Health 2017;4(2):e19. Disponível em: <https://mental.jmir.org/2017/2/e19>. Acesso em: 22 jun. 2025.

GIL, Antonio Carlos. **Como Elaborar Projetos de Pesquisa**. 6ª ed. São Paulo: Atlas, 2017.

GOOGLE. **MediaPipe**. Disponível em: <https://developers.google.com/mediapipe>. Acesso em: 22 out. 2023.

IBM. **O que é análise de sentimento?** Disponível em: <https://www.ibm.com/br-pt/topics/sentiment-analysis> Acesso em: 21 jun. 2025.

KAUSHIK, P., Parihar, S., Khalid, M.S., Chandra, U., Josphin, J., Dept, M., & of (2024). **Enhancing Emotional Support Chatbots Using Deep Learning & NLP: A Study on Personalization and Effectiveness**. 2024 1st International Conference on Advances in Computing, Communication and Networking (ICAC2N), 1416-1421.

LUDERMIR, Teresa Bernarda. **Inteligência Artificial e Aprendizado de Máquina**: estado atual e tendências. Estudos Avançados, [S.L.], v. 35, n. 101, p. 85-94, abr. 2021. Disponível em: <https://www.scielo.br/j/ea/a/wXBdv8yHBV9xHz8qG5RCgZd#>. Acesso em: 21 out. 2023.

MEDLEY. **Ansiedade e depressão**. Disponível em: www.medley.com.br/saude-e-bem-estar/saude-mental/artigos/ansiedade-e-depressao Acesso em: 20 mar. 2025.

NLTK, **Natural Language Toolkit**. Disponível em: <https://www.nltk.org>. Acesso em: 14 jun. 2025

ONODY, Roberto. **Teste de Turing e Inteligência Artificial**. Disponível em: <https://www2.ifsc.usp.br/portal-ifsc/teste-de-turing-e-inteligencia-artificial/>. setembro de 2021. Acesso em: 21 jun. 2025

ORACLE, **O que é um chatbot?** Disponível em: <https://www.oracle.com/br/chatbots/what-is-a-chatbot/>. Acesso em: 14 jun. 2025.

ORGANIZAÇÃO MUNDIAL DA SAÚDE (OMS). **OMS destaca a necessidade urgente de transformar a saúde mental e a atenção à saúde mental**. Disponível em: <https://www.paho.org/pt/noticias/17-6-2022-oms-destaca-necessidade-urgente-transformar-saude-mental-e-atencao> Acesso em: 20 mar. 2025.

ORGANIZAÇÃO PAN-AMERICANA DA SAÚDE (OPAS). (2022). **Uso da inteligência artificial na saúde mental: oportunidades e desafios**. Disponível em: <https://www.paho.org/pt/documentos/uso-da-inteligencia-artificial-na-saude-mental-oportunidades-e-desafios>. Acesso em: 20 mar. 2025.

PARRIS, Eilidih. **PyTorch – deep learning framework for fast, flexible experimentation.** Disponível em: <https://www.linuxlinks.com/pytorch-deep-learning-framework-for-fast-flexible-experimentation/>. November 10, 2023. Acesso em: 14 jun. 2025

RED HAT, **What is a REST API?** Disponível em: <https://www.redhat.com/en/topics/api/what-is-a-rest-api>. May 8, 2020. Acesso em: 14 jun. 2025

RUSSELL, Stuart J.; NORVIG, Peter. **Inteligência Artificial.** Rio de Janeiro: Grupo GEN, 2013. E-book. ISBN 9788595156104. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9788595156104/>. Acesso em: 04 out. 2023.

SÁ, Yuri Vasconcelos de A. **Desenvolvimento de aplicações IA: robótica, imagem e visão computacional.** São Paulo: Editora Saraiva, 2021. E-book. ISBN 9786589881681. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9786589881681/>. Acesso em: 22 out. 2023.

SAS, **Processamento de Linguagem Natural O que é e qual sua importância?** Disponível em: https://www.sas.com/pt_br/insights/analytics/processamento-de-linguagem-natural.html. Acesso em: 14 jun. 2025

SCALABRIN, E.E. (2025). **Introdução ao processamento de linguagem natural.** THE PYTORCH Team, **Optimizing CUDA Recurrent Neural Networks with TorchScript.** Disponível em: <https://pytorch.org/blog/optimizing-cuda-rnn-with-torchscript/>. May 1, 2019 Acesso em: 14 jun. 2025

UFAM. **Chatbot terapêutico utiliza inteligência artificial para atendimento emocional e psicológico.** Disponível em: <https://www.ufam.edu.br/noticias-destaque/6257-chatbot-terapeutico-utiliza-inteligencia-artificial-para-atendimento-emocional-e-psicologico.html>. Novembro 2024. Acesso em: 22 jun. 2025

APÊNDICE A - Repositorio no GitHub do Back-end

A seguir, apresenta-se o link de acesso ao repositório do código-fonte do Back-end desenvolvido para este trabalho, disponível no GitHub:

<https://github.com/Thiago-Taboada/psico-chatbot-py>

Além disso, a seguir está um QR Code para facilitar o acesso:

Figura 18-QR Code para acesso ao repositório do GitHub do Back-end



Fonte: Autores, 2025

APÊNDICE B - Repositorio no GitHub do Front-end

A seguir, apresenta-se o link de acesso ao repositório do código-fonte do Front-end desenvolvido para este trabalho, disponível no GitHub:

https://github.com/Thiago-Taboada/MoodBalance_AI

Além disso, a seguir está um QR Code para facilitar o acesso:

Figura 19-QR Code para acesso ao repositório do GitHub do Front-end



Fonte: Autores, 2025