



DESENVOLVIMENTO DE UM CHATBOT COM INTELIGÊNCIA ARTIFICIAL PARA APLICAÇÃO NA TRIAGEM DE SINAIS DE DEPRESSÃO EM TRABALHADORES ¹

**Thiago Monteiro Fronza², Pedro Manerich Nicolau³, Cleidson Arthur Sousa de Sousa⁴,
Gabriel Ronney da Silva⁵, Diego de Castro Rodrigues⁶, Marcela Purificação⁷,**

¹ Projeto de pesquisa desenvolvido no Centro de Inovação SESI em Tecnologias para a Saúde.

² Graduado em Biomedicina (UNIPLAC) e Tecnólogo em Análise e Desenvolvimento de Sistemas (SENAI/SC). Atua como Pesquisador em Saúde no Centro de Inovação SESI em Tecnologias para Saúde - CISTech. E-mail: thiago.fronza@sesisc.org.br

³ Mestre em Engenharia de Transportes e Gestão Territorial (UFSC). Atua como Gerente de Projetos no Centro de Inovação SESI em Tecnologias para Saúde - CISTech. E-mail: pedro.nicolau@sesisc.org.br

⁴ Graduado em Engenharia Biomédica (UFPA). Atua no Centro de Inovação SESI em Tecnologias para Saúde - CISTech. E-mail: cleidson.sousa@sesisc.org.br

⁵ Graduado em Gestão da Tecnologia da Informação (UNC). Atua como Pesquisador em Software e Tecnologia no Centro de Inovação SESI em Tecnologias para Saúde - CISTech. E-mail: gabriel.r.silva@sesisc.org.br

⁶ Doutor em Ciências da Computação (UFG). Atua no Centro de Inovação SESI em Tecnologias para Saúde - CISTech. E-mail: diego.c.rodrigues@sesisc.org.br

⁷ Mestre em Biotecnologia (UFSC). Coordenadora do Centro de Inovação SESI em Tecnologias para Saúde - CISTech. E-mail: marcela-purificacao@sesisc.org.br

RESUMO

Este artigo aborda o desenvolvimento de um chatbot para triagem de sinais de depressão em trabalhadores a partir do instrumento PHQ-9. A depressão é um dos transtornos mentais mais comuns mundialmente e a informatização na atenção primária à saúde pode fortalecer as práticas de cuidado. A Inteligência Artificial é uma ferramenta utilizada na informatização da saúde, que pode aumentar a eficácia dos serviços. O chatbot foi criado com técnicas de *Machine Learning* e processamento de linguagem natural, reproduzindo diálogos humanizados que criam conforto para o usuário. Após a triagem realizada pelo chatbot, ele apresenta um *feedback* com indicações de ajuda dentro ou fora da empresa, e, em casos nos quais se identifica riscos à vida, os profissionais da saúde responsáveis são informados para que haja urgência no atendimento. Para o projeto do chatbot, foi utilizado a linguagem Python, o *framework* TensorFlow e a biblioteca NLTK para o aprendizado de máquina.

INTRODUÇÃO

A depressão é um dos transtornos mentais mais comuns no mundo, abrangendo cerca de 5% da população segundo a Organização Mundial da Saúde (OMS). Ela é caracterizada por alterações de pensamento, humor e comportamento, interferindo nas relações sociais e ocupacionais do indivíduo (PHAC, 2006). No Brasil, transtornos mentais e comportamentais ocupam o terceiro lugar nas causas de afastamento das atividades laborais (RODRIGUES; CALHEIROS, 2019), transtornos esses ocasionados por diferentes aspectos da vida do indivíduo, como relacionamentos, situação financeira, além de outros aspectos no ambiente de trabalho, como o medo de não ser capaz de desempenhar o trabalho de forma adequada, ao mesmo tempo de não



estar verdadeiramente à altura das novas exigências, como o tempo, a formação, a informação, experiência e principalmente a cultura e ideologia da organização (OLIVEIRA, 2019).

A atenção primária aos quadros depressivos é de extrema importância devido ao seu potencial de tratamento, logo, a triagem dos sinais de depressão por meio de questionários práticos tem sido grandemente utilizada (DUNCAN, 2013). O *Patient Health Questionnaire-9* (PHQ-9) é um dos instrumentos de triagem de depressão mais comuns, sendo baseado no PRIME-MD, que é um instrumento de identificação de cinco transtornos mentais comuns em atenção primária à saúde. O PHQ-9 se caracteriza por uma aplicação rápida pelo seu número de perguntas (9 perguntas), o que gera uma vantagem em estudos epidemiológicos (SANTOS et al., 2013).

A informatização na atenção primária à saúde fortalece os processos de trabalho e práticas de cuidado, visto que garantem uma maior velocidade de gestão de informações e processamento de dados clínicos do paciente, assim como facilitam os registros e armazenamento desses dados (MONTAGUE, 2014; RITTENHOUSE et al., 2017). Atualmente, uma das ferramentas mais utilizadas no processo de informatização da saúde é a Inteligência Artificial, já que permite uma maior precisão no diagnóstico de doenças, dado que sua autonomia e capacidade de processos garantem uma alta performance aumentando a eficácia dos serviços médicos e de outros profissionais da saúde (LEMES; LEMOS, 2020).

Em razão às necessidades de cuidado e atenção primária aos trabalhadores e utilizando a informatização para melhorar a reprodutibilidade de questionários de triagem e otimização da avaliação, foi criado um chatbot que, por meio de técnicas de *Machine Learning* e processamento de linguagem natural ou NLP (*Natural Language Processing*), reproduz diálogos humanizados, criando um ambiente de conforto para o usuário. Durante as interações com o usuário, caso o chatbot venha a perceber indícios de tristeza, raiva ou outros sentimentos que possam indicar sinais de depressão, ele indica ao usuário o PHQ-9 como forma de ajuda, podendo este aceitar ou não responder após ter acesso ao termo de consentimento.

Após a triagem realizada pelo chatbot com o PHQ-9, de acordo com as respostas é estabelecido o nível dos sinais relacionados à depressão do usuário, a ferramenta então disponibiliza uma resposta específica para cada nível, oferecendo indicações de hábitos e atitudes que contribuem na melhora dos sinais e, em alguns casos, recomenda a procura por ajuda profissional, dentro ou fora da empresa. Nos casos em que apresentam indícios de riscos à integridade e vida do



indivíduo, o chatbot informa aos profissionais da saúde previamente cadastrados para que ações rápidas possam ser tomadas, visando minimizar quaisquer riscos ao usuário que respondeu. Este processo é previsto na Lei Geral de Proteção de Dados (LGPD), onde a quebra do sigilo dos dados da pessoa é permitida quando identificado o risco à sua vida.

METODOLOGIA

Para o projeto do chatbot foi utilizada a linguagem Python, o *framework* TensorFlow e a biblioteca NLTK para o aprendizado de máquina. O TensorFlow é um instrumento de *Machine Learning* (aprendizado de máquina), um *framework* para computação numérica utilizando grafos computacionais para criação e treinamento da rede neural para detectar e decifrar padrões e correlações, análogo à forma humana de aprender e raciocinar (GALEONE, 2019; GANEGEDARE, 2018).

Para a finalidade de aprendizado do chatbot, foi escolhida a rede neural LSTM (*Long Short Term Memory*), uma rede neural recorrente (RNN), que possui a capacidade de classificar eventos a partir de eventos anteriores sem um intervalo de tempo definido, tornando assim uma ótima rede RNN para a aplicação desejada (HOCHREITER; SCHMIDHUBER, 1997).

A biblioteca NLTK (*Natural Language Toolkit*) é uma ferramenta de processamento de linguagem natural (PLN) que auxilia na interpretação da linguagem humana, ou seja, na forma de falar e de se expressar, para uma melhor compreensão do *bot* sobre, principalmente, a escrita. Possui diversos recursos como bibliotecas de classificação de textos, tokenização, marcação, análise e raciocínio semântico (BARBOSA et al., 2017; JOACHIMS, 2002).

O chatbot é baseado no uso de padrões de entrada e respostas predefinidas. Em seguida, utiliza uma abordagem heurística para selecionar a resposta apropriada. É um chatbot orientado a objetivos, onde pode-se personalizar o tom e o fluxo para levar os usuários à melhor experiência. Nesse caso, o chatbot foi construído usando técnicas de *deep learning*, sendo treinado no conjunto de dados que contém categorias (intenções), padrão e respostas, usando a rede neural LSTM para classificar a qual categoria a mensagem do usuário pertence e então trazendo a resposta aleatória da lista de respostas.

Ao trabalhar com dados de texto, é necessário realizar diversos pré-processamentos dos dados antes de fazer um aprendizado de máquina ou um modelo de aprendizado profundo. A tokenização é a primeira e mais básica técnica que pode ser realizada com dados de texto,



segmentando palavras dos textos e identificando seus limites, ou seja, onde uma palavra termina e a outra começa (INDURKHYA; DAMERAU, 2010; BARBOSA et al., 2017).

A próxima etapa de processamento do texto é a lematização, cuja função é transformar a palavra em sua forma base para agrupar as diferentes configurações desta palavra em uma só, chamada de lema, eliminando, assim, a duplicação de palavras e a desambiguação (INDURKHYA; DAMERAU, 2010; BARBOSA et al., 2017). Por fim, é realizada a serialização dos objetos que serão utilizados durante a previsão, por meio do módulo *pickle*, permitindo, assim, a permanência desses objetos enquanto necessário.

Com os dados prontos após o pré-processamento, sendo as entradas da rede neural os padrões e as saídas das classes às quais os padrões pertencem, pode-se iniciar o processo de treinamento da rede neural. Para a construção do modelo, foi utilizada uma rede neural profunda de 3 camadas, sendo a primeira com 128 neurônios, a segunda com 64 neurônios e a última sendo a camada de saída com o número de neurônios necessários para o modelo.

Para a estruturação do modelo, foi escolhida a API sequencial Keras, uma biblioteca de rede neural em Python. Sendo permitida a sua utilização com TensorFlow, ela permite um rápido ensaio com redes neurais profundas e de forma prática.

Para lidar com o fluxo fixo do questionário do PHQ-9, foi desenvolvido uma API utilizando Python e Angular. Essa API realiza consultas, tratamentos e gravação das questões do PHQ-9 no banco de dados PostgreSQL. Dentro dos padrões pré-definidos do chatbot, foram estabelecidos “gatilhos”, que são palavras identificadas como possíveis sinais de tristeza, depressão, falta de ânimo, e, ao serem identificadas pelo chatbot, fazem com que este proponha ao usuário que responda ao questionário PHQ-9.

O PHQ-9 utiliza a escala de Likert no modelo de frequência (“Nenhuma vez”, “Vários dias”, “Mais da metade dos dias” e “Quase todos os dias”), já que essa escala apresenta opções de respostas descritivas que variam entre dois extremos, permitindo identificar diferentes níveis de intensidade, o que a torna uma das ferramentas mais utilizadas na montagem de pesquisas (THURSTONE; CHAVE, 1929). Cada uma das respostas possui um peso (0, 1, 2 e 3, respectivamente), que são somados para definir a classificação do usuário em: Sem sintomas (soma \leq 4), Sintomas mínimos ($4 < \text{soma} \leq 9$), Sintomas leves ($9 < \text{soma} \leq 14$), Sintomas moderados ($14 < \text{soma} \leq 19$) e Sintomas graves (soma > 19) (KROENKE et al., 2001). Todos esses cálculos são realizados em Python, e, para cada escala de classificação, o chatbot envia um feedback ao usuário, com dicas e orientações que podem ajudá-lo e levá-lo a procurar um

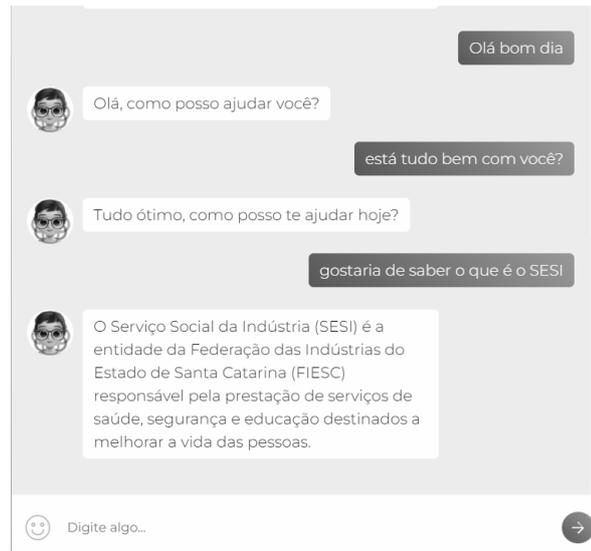


profissional da área da saúde, e também a opção de compartilhar suas respostas com seu líder imediato na empresa, setor de RH ou com o responsável de saúde, todos previamente cadastrados.

RESULTADOS

Após o treinamento do modelo para classificação dos padrões de perguntas, utilizando uma rede neural LSTM por 200 épocas, foi alcançado um alto grau de precisão da rede neural, fazendo com que as respostas pré-definidas se adequassem aos padrões de perguntas realizadas pelo usuário, como interações de cumprimentos, questionamentos e frases de afirmação, conforme apresentado na Figura 1.1.

Figura 1.1: Respostas do chatbot às interações do usuário.

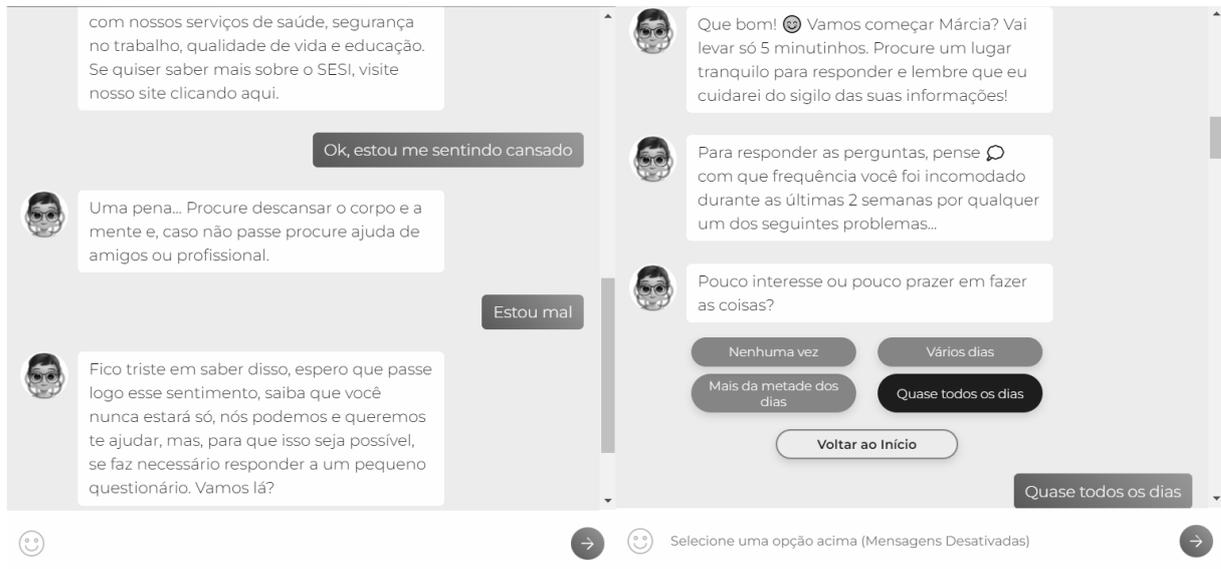


Fonte: Autor (2023).

A identificação de emoções pelo chatbot como alegria, raiva, cansaço, tristeza e anseio também apresentou alto grau de precisão, conseguindo identificar os “gatilhos” em frases que apresentam emoções como raiva, tristeza e ansiedade, indicando, assim, a possibilidade de responder ao questionário do PHQ-9 para iniciar a triagem de sinais de depressão, como apresentado na Figura 1.2.



Figura 1.2: Identificação de gatilho e apresentação do questionário PHQ-9.



Fonte: Autor (2023).

As pontuações obtidas pela soma das respostas do PHQ-9 também foram testadas em todas as 28 possibilidades de resultados, desde a soma mínima de 0 pontos até a soma máxima de 27 pontos, validando que todas as respostas sejam classificadas adequadamente nas escalas de sintomas, e todas as escalas retornando seus respectivos feedbacks, onde nas escalas de sintomas moderados e sintomas graves, ela reforça a importância de compartilhar suas respostas com algum responsável de sua equipe (líder, RH e saúde), para que possa receber a ajuda necessária, como demonstrado na Figura 1.3.

Figura 1.3: Feedback do chatbot para usuário que alcança Sintomas graves no PHQ-9.



Fonte: Autor (2023).



DISCUSSÃO

Os resultados apresentados indicam alto grau de precisão na classificação de padrões de perguntas e na identificação de emoções pelo chatbot. A precisão alcançada é um bom indicador de que o modelo treinado é capaz de reconhecer corretamente as perguntas e as emoções apresentadas pelos usuários e, assim, fornecer respostas adequadas. Além disso, o modelo também foi capaz de classificar corretamente as respostas do questionário PHQ-9, validando sua capacidade de triagem de sinais de depressão.

No entanto, é importante destacar que esses resultados foram obtidos em um ambiente controlado, onde as informações foram geradas artificialmente e não representam a complexidade e a diversidade das interações do mundo real. Portanto, é necessário avaliar o desempenho do modelo em condições mais desafiadoras e avaliar sua capacidade de lidar com situações e problemas imprevistos que possam surgir.

Além disso, é importante lembrar que o uso de chatbots e modelos de IA para triagem de sinais de depressão deve ser realizado com cuidado, pois eles não substituem a avaliação de um profissional de saúde. O chatbot pode ser útil como um recurso complementar e/ou de triagem inicial, mas não deve ser considerado como uma fonte de diagnóstico e única. Portanto, é importante garantir que os usuários tenham acesso a profissionais qualificados para avaliação e tratamento adequado, caso necessário.

CONCLUSÕES

Com base no desenvolvimento de um chatbot para triagem de sinais de depressão em trabalhadores, utilizando o instrumento PHQ-9, é possível afirmar que a informatização da saúde pode fortalecer as práticas de cuidado e a Inteligência Artificial é uma ferramenta que pode aumentar a eficácia dos serviços. O chatbot foi criado com técnicas de *Machine Learning* e processamento de linguagem natural, reproduzindo diálogos humanizados que criam conforto para o usuário. Após a triagem, ele apresenta um feedback com indicações de ajuda dentro ou fora da empresa, e, em casos de risco à vida, os profissionais da saúde são informados para que haja urgência no atendimento.

Com o avanço da tecnologia e a crescente necessidade de cuidado e atenção primária à saúde, espera-se que o uso de chatbots e outras ferramentas de Inteligência Artificial se torne cada vez



mais comum na área da saúde, auxiliando profissionais e pacientes em diversas tarefas, como triagem, diagnóstico e monitoramento de condições de saúde, melhorando os acessos à informação e aumentando a rapidez no atendimento aos pacientes.

Além disso, é importante destacar a necessidade de seguir as normas de proteção de dados pessoais, como a LGPD, para garantir a privacidade e segurança das informações dos pacientes, além de gerar maior confiança no trabalho. É ressaltar que essa tecnologia deve ser utilizada em conjunto com os profissionais da saúde, não substituindo a avaliação clínica e o tratamento adequado.

Ainda é necessário realizar pesquisas para validar a eficácia do chatbot na triagem de sinais de depressão e outros transtornos mentais, pois os testes foram feitos com dados fictícios, não tendo a validação com usuários reais, passo que está sendo planejado para a continuidade do projeto. Posteriormente, será possível observar o impacto da utilização do chatbot na saúde mental dos participantes, considerando fatores como redução do estresse e melhora da qualidade de vida, identificando desafios e limitações do projeto; como por exemplo a necessidade de atualização constante do chatbot e a possível resistência dos trabalhadores em utilizar a tecnologia. Além de analisar as considerações éticas e regulatórias envolvidas na utilização do chatbot, como a privacidade dos dados dos usuários e a responsabilidade dos profissionais de saúde em casos de risco à vida. Entretanto, um fato é que cada vez mais as tecnologias se mostram como aliadas e ferramentas importantes para avaliar e melhorar a saúde e o bem-estar das pessoas.

PALAVRAS-CHAVE: Depressão, Saúde, Tecnologias, Inteligência Artificial, chatbot.

REFERÊNCIAS

BARBOSA, Jaderson L. N. et al. **Introdução ao Processamento de Linguagem Natural usando Python**. Piauí: I Escola Regional de Informática do Piauí. Livro Anais - Artigos e Minicursos, v. 1, n. 1, p. 336-360, 2017.

DUNCAN, Bruce B. et al. **Medicina ambulatorial: Conduas de Atenção Primária Baseadas em Evidências**. 4. ed. Porto Alegre: ARTMED, 2013.

GALEONE, Paolo. **Hands-On Neural Networks with TensorFlow 2.0**. Birmingham: PACKT Publishing Ltd, 2019.

GANEGEDARE, Thushan. **Natural Language Processing With TensorFlow**. Birmingham: PACKT Publishing Ltd, 2018.



HOCHREITER, S.; SCHMIDHUBER, J. **Long short-term memory**. Neural Computation, 9(8):1735–1780, 1997.

INDURKHYA, N.; DAMERAU, F. J. **Handbook of natural language processing**. Flórida: CRC Press, 2010.

KROENKE, Kurt et al. **The PHQ-9: Validity of a Brief Depression Severity Measure**. Journal of General Internal Medicine, v. 16, p. 606-613, 2001.

LEMES, Marcelle M.; LEMOS, Amanda N. L. E. **O uso da inteligência artificial na saúde pela Administração Pública Brasileira**. Brasília: Cadernos Ibero-Americanos de Direito Sanitário; v. 9 n. 3, 2020.

MONTAGUE, E. **The promises and challenges of health information technology in primary health care**. Evanston: Primary Health Care Research Development; 15(3):227-30, 2014.

OLIVEIRA, L. A. F. **O prazer-sofimento psíquico no trabalho e a perspectiva de Christophe Dejours**. Aracajú: Revista Psicologia & Saberes 8 (11), 2019.

Public Health Agency of Canada. **The Human Face of Mental Health and Mental Illness in Canada 2006**. Ottawa, Ont.:PHAC, 2006.

RITTENHOUSE, Diane R. et al. **Increased Health Information Technology Adoption and Use Among Small Primary Care Physician Practices Over Time: A National Cohort Study**. California: Annals of Family Medicine; 15(1):56-62, 2017.

RODRIGUES, Paula E. B.; CALHEIROS, Maria I. M. Q. **Transtornos mentais relacionados ao trabalho no Brasil e a psicodinâmica do trabalho**. Farol - Revista de Estudos Organizacionais e Sociedade, 6(16),551-601, 2019).

SANTOS, Iná S. et al. **Sensibilidade e especificidade do Patient Health Questionnaire-9 (PHQ-9) entre adultos da população geral**. Pelotas: Cad. Saúde Pública 29 (8), 2013.

THURSTONE, L. L.; CHAVE, E. J. **The Measurement of Attitude: A Psychophysical Method and Some Experiments With a Scale for Measuring Attitude Toward the Church**. Chicago, University of Chicago Press, 1929.