

Um Modelo Computacional para Análise de Depressão em Dados de Redes Sociais

Alexandre Augusto Foppa¹, Jorge Luis Vitória Barbosa¹

¹Programa de Pós-graduação em Computação Aplicada (PPGCA)
Universidade do Vale do Rio dos Sinos (Unisinos)
Av. Unisinos, 950 – Bairro Cristo Rei – 93022-750 – São Leopoldo – RS – Brasil

alexandrefo@edu.unisinos.br, jbarbosa@unisinos.br

Abstract. *Mental health disorders affect millions, compromise quality of life, and reduce productivity. Depression impacts around 5% of adults worldwide and costs nearly US\$1 trillion annually. We propose Serapis, a computational model that organizes data from social networks, questionnaires, and the PHQ-9 to produce actionable intelligence for depression diagnosis. Our model integrates LLMs with an ontology built on best practices in forensic computing and OSINT. We developed an MVP prototype that builds a timeline of posts and highlights entries relevant to psychologists. A focus group with professionals validated the system's usability, reporting high ease of use and perceived utility, and recommended improvements in contextual accuracy and collaboration features.*

Resumo. *Os transtornos mentais prejudicam a vida de milhões, comprometem a qualidade de vida e reduzem a produtividade. A depressão impacta cerca de 5% dos adultos em todo o mundo e gera custos anuais próximos a US\$1 trilhão. Propomos o Serapis, um modelo computacional que organiza dados de redes sociais, questionários e do PHQ-9 para produzir inteligência acionável e apoiar o diagnóstico da depressão. O modelo integra LLMs com uma ontologia construída segundo as melhores práticas de computação forense e OSINT. Desenvolvemos um protótipo MVP que constrói uma linha do tempo de postagens e destaca entradas relevantes para psicólogos. Um grupo focal com profissionais validou a usabilidade do sistema, apontando alta facilidade de uso e utilidade, e recomendou melhorias na acurácia contextual e na colaboração.*

1. Introdução

Segundo a Organização Mundial da Saúde [WHO 2022], a saúde mental é um direito fundamental e requer abordagens estruturadas para sua garantia. Em 2022, aproximadamente um bilhão de pessoas foram afetadas por transtornos mentais, tornando-os a principal causa de anos vividos com incapacidade. A depressão, um dos transtornos mais comuns, impacta cerca de 5% da população adulta e gera custos globais estimados em US\$ 1 trilhão anualmente [APA 2022]. O diagnóstico e o tratamento adequados exigem a análise detalhada do histórico do paciente, um processo que pode levar semanas e demanda um esforço significativo dos profissionais de saúde mental.

A escassez de profissionais qualificados e a complexidade da análise de casos tornam a inteligência artificial (IA) uma alternativa promissora para apoiar esse processo.

Estudos indicam que a IA pode otimizar tarefas como a organização de informações clínicas e a identificação de padrões relevantes para o diagnóstico [Allen 2020]. Entre as abordagens exploradas, a *Social Media Intelligence (SOCMINT)*, um subgrupo da *Open Source Intelligence (OSINT)*, se destaca por utilizar dados de redes sociais acessíveis publicamente, viabilizando a aplicação de IA sem a necessidade de coletar informações privadas [Schaure and Störger 2013]. Essa abordagem permite identificar padrões e tendências a partir de conteúdos que os próprios usuários compartilham. Trabalhos anteriores exploraram a aplicação de IA à saúde mental com foco na ideação suicida e classificação textual [Heckler et al. 2022, Heckler et al. 2023]. Neste trabalho, no entanto, a análise se limita exclusivamente a dados voluntariamente fornecidos, transformando essas informações em inteligência acionável para apoiar o diagnóstico da depressão, respeitando a dinâmica do vínculo terapêutico.

Apesar do potencial da SOCMINT, desafios técnicos e éticos ainda precisam ser superados para garantir a confiabilidade e a privacidade dos dados analisados [Ebner-Priemer et al. 2020]. Neste contexto, este artigo apresenta o Serapis, um modelo computacional que organiza e analisa dados de redes sociais e instrumentos clínicos para gerar inteligência acionável e apoiar o diagnóstico da depressão. O modelo utiliza uma ontologia para estruturar informações de forma transparente e acessível, facilitando a tomada de decisão dos profissionais de saúde mental. Além disso, o artigo detalha o desenvolvimento de um protótipo e sua avaliação junto a psicólogos, explorando o potencial da tecnologia para aprimorar processos clínicos.

O artigo divide-se em seis seções: a Seção 2 apresenta trabalhos relacionados, a Seção 3 detalha o modelo (arquitetura e ontologia), a Seção 4 descreve implementação e avaliação, a Seção 5 discute resultados, e a Seção 6 conclui com propostas futuras.

2. Trabalhos Relacionados

Realizou-se uma revisão sistemática da literatura entre janeiro e fevereiro de 2023, consultando ACM Digital Library, IEEE Xplore, Science Direct, Springer, PsyArticles, PubMed Central e JMIR, o que resultou em 6.573 estudos iniciais. Após a triagem por título e palavra-chave (2.412), exclusão de trabalhos fora do escopo (893), leitura de resumos (335) e aplicação final do método de três leituras (113), obteve-se um conjunto de 49 artigos. Devido às limitações de espaço, este artigo apresenta apenas os estudos mais diretamente ligados ao escopo da pesquisa. A Tabela 1 resume a análise dessas publicações e as compara ao modelo proposto.

A Tabela 1 compara os estudos selecionados com base em doze critérios que avaliam diferentes aspectos da coleta, processamento e análise dos dados. Esses critérios incluem a plataforma utilizada, o transtorno mental analisado, a fase do tratamento abordada e o critério de diagnóstico adotado. Além disso, a tabela identifica o uso de metadados, dados demográficos e imagens para melhorar o desempenho do modelo, bem como a possibilidade de validação profissional e diagnóstico diferencial. Outros critérios analisam a presença de registro de consentimento, sumarização das informações pelo paciente, técnicas de processamento de texto e os métodos de aprendizado de máquina empregados.

Todos os estudos analisam a detecção de possíveis casos de depressão a partir de sinais indiretos em redes sociais. Ricard et al. [2018] investigaram se legendas e comentários no Instagram© poderiam prever a pontuação no PHQ-8, comparando um

Tabela 1. Comparação dos estudos relacionados

Informações Gerais					Características Técnicas							
Referência	Plataforma	Transtorno Mental	Fase do Tratamento	Critério de Diagnóstico	Meta-dados	Demo-grafia	Imagens	Validação	Consent.	Sumariz.	Proc. de Texto	Téc. de ML
Ricard et al. (2018)	Instagram	Depressão	Diagnóstico	Aplicação de Questionário	Não	Não	Não	Não	Sim	Não	ANEW, LabMT, Emoji Sentiment Score, Detector de Idioma do Google	Regressão Linear
Manikonda and De Choudhury (2017)	Instagram	Depressão, Bipolaridade, Esquizofrenia e Anorexia	Diagnóstico	Análise dos Critérios do DSM	Sim	Não	Sim	Não	Não	Não	LDA, SURF, LIWC	PCA
Seabrook et al. (2018)	Facebook e Twitter	Depressão	Diagnóstico	Aplicação de Questionário	Sim	Não	Não	Sim	Não	Não	LIWC	Nenhum
Yang et al. (2020)	Facebook	Depressão	Diagnóstico	Aplicação de Questionário	Sim	Não	Não	Não	Não	Não	Stemming, Tokenização, TF-IDF, LIWC	CART
Islam et al. (2018)	Facebook	Depressão	Diagnóstico	Autodeclaração	Não	Não	Não	Não	Não	Não	LIWC	Árvore de Decisão
Jain et al. (2020)	Instagram	Depressão	Diagnóstico	Autodeclaração	Sim	Não	Sim	Não	Não	Não	Google Translate	Rede Neural, Random Forest
Chen et al. (2020)	Facebook	Depressão	Diagnóstico	Aplicação de Questionário	Não	Não	Não	Não	Não	Não	SentiStrength, LDA, LIWC	HMM e GP Regression
Wongkoblal et al. (2019)	Facebook	Depressão	Diagnóstico	Aplicação de Questionário	Não	Não	Não	Não	Não	Não	Nenhum	K-Means, MIL (LSTM e GRU)
Modelo Serapis	Instagram e Facebook	Depressão	Diagnóstico, Prognóstico e Gestão	Identificação Profissional	Sim	Sim	Não	Sim	Sim	Sim	GPT LLM	Inferência Contextual Assistida

modelo baseado apenas nos dados do usuário com outro enriquecido pelos dados de sua rede de contatos. Apenas a segunda abordagem apresentou significância estatística. Manikonda and De Choudhury [2017] analisaram a relação entre texto e imagens no Instagram© entre indivíduos que declararam ter depressão, transtorno bipolar, esquizofrenia ou anorexia. O estudo combinou histogramas em escala de cinza, saliência visual e processamento de texto para identificar padrões de comportamento.

Seabrook et al. [2018] avaliaram Facebook© e Twitter©, utilizando o aplicativo MoodPrism para coletar atualizações de status e pontuações no PHQ-9. No Facebook©, a instabilidade emocional foi associada a uma maior probabilidade de depressão, enquanto no Twitter© a mesma característica teve um efeito protetor, indicando menor risco da condição. Yang et al. [2020] analisaram a depressão no Facebook© utilizando um framework que inferia a pontuação do questionário a partir dos dados já disponíveis, sem exigir que os usuários preenchessem o formulário. O modelo CART foi aplicado para identificar sinais de depressão a partir de aspectos semânticos e métricas de redes sociais.

Islam et al. [2018] classificaram comentários do Facebook© como depressivos ou não, utilizando LIWC para extrair escores emocionais, temporais e linguísticos. A classificação foi realizada por um modelo de Árvore de Decisão. Jain et al. [2020] analisaram a depressão na população indiana, processando texto e imagens do Instagram©. O estudo utilizou Google Translate para traduzir postagens do hindi para o inglês e testou diferentes algoritmos de aprendizado de máquina, com Redes Neurais e *Random Forest* apresentando os melhores resultados.

Chen et al. [2020] e Wongkoblal et al. [2019] utilizaram o conjunto de dados *myPersonality* para analisar a depressão no Facebook©. Chen et al. [2020] investigaram

a flutuação de humor como proxy, empregando SentiStrength, LDA e LIWC no processamento de texto. Para modelagem, aplicaram regressão gaussiana e um modelo de Markov oculto (HMM). Wongkoblap et al. [2019] exploraram aprendizado de múltiplas instâncias (MIL) com LSTM e GRU para classificar usuários. Em vez de utilizar geração de características, o modelo combinou codificação de postagens, mecanismos de atenção e classificação de usuários.

O modelo Serapis preenche uma lacuna na detecção de depressão, oferecendo uma abordagem direcionada para a tomada de decisão clínica, enquanto os modelos existentes dependem de autodeclaração ou questionários. Ele processa e organiza dados de redes sociais em um Histórico de Contextos, permitindo a comparação estruturada com critérios do DSM-V por meio de um modelo de linguagem natural de grande escala (LLM). Além disso, viabiliza o registro de consentimento no aplicativo, gera sumarizações automatizadas e facilita o acompanhamento clínico e prognóstico. Um diferencial importante é o controle de acesso baseado em senha: ao compartilhar seus dados, o paciente define uma senha pessoal, garantindo que apenas os profissionais autorizados por ele possam acessá-los. Dessa forma, o Serapis amplia as possibilidades de suporte a profissionais de saúde mental, fornecendo inteligência contextualizada para diagnóstico e gestão do tratamento, ao mesmo tempo em que reforça a privacidade e a autonomia do paciente, superando limitações dos métodos tradicionais.

3. Modelo Serapis

Esta seção apresenta o Serapis, um modelo de inteligência artificial aplicado à saúde mental, baseado nos princípios da SOCMINT. O modelo segue o Ciclo de Inteligência, um processo estruturado para transformar dados brutos em inteligência relevante, conforme definido pelo *Office of the Director of National Intelligence* [Böhm and Lolagar 2021, Larsen 2022].

3.1. Visão Geral

Para operacionalizar esse ciclo, o Serapis estrutura sua funcionalidade em seis etapas, conforme ilustrado na Figura 1. A primeira etapa (Direção) define os critérios diagnósticos utilizados pelo modelo, baseando-se no DSM e na CID. Na segunda etapa (Coleta), um aplicativo obtém o consentimento do indivíduo, coleta dados demográficos e histórico clínico e extrai informações de redes sociais. A terceira etapa (Processamento) organiza esses dados na *Serapis Personal Mental Health Ontology (SPMH)*, aplicando técnicas de pré-processamento e análise de sentimentos.

A quarta etapa (Análise) utiliza um LLM para gerar um relatório inicial sobre a condição do paciente, permitindo que profissionais de saúde acessem as informações e solicitem detalhamentos. Na quinta etapa (Disseminação), a inteligência gerada é apresentada ao profissional em uma interface conversacional. A sexta etapa (Feedback) viabiliza a validação da análise pelo profissional, que pode inserir novas informações e refinar a inteligência gerada, garantindo um acompanhamento clínico estruturado.

Para otimizar esse processo, o Serapis adota um sistema multiagente, no qual diferentes agentes desempenham funções específicas, como captura de dados, organização de informações e atualização contínua da inteligência gerada. Esse mecanismo permite que o modelo se adapte dinamicamente ao contexto clínico, oferecendo suporte ao diagnóstico e à gestão do tratamento.

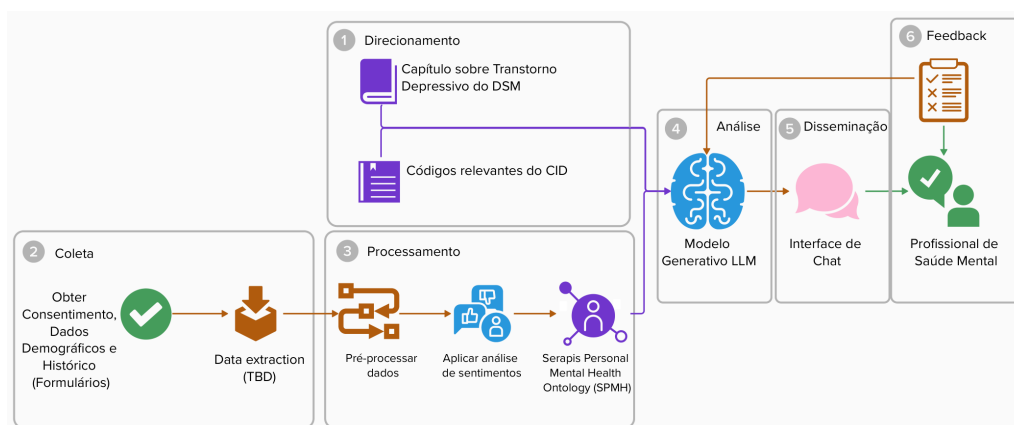


Figura 1. Fluxo por etapas do ciclo de inteligência

3.2. Arquitetura

O modelo Serapis foi projetado seguindo os princípios da *Technical Architecture Modeling (TAM)* [SAP 2007], permitindo a representação estruturada dos componentes do sistema. A Figura 2 apresenta a arquitetura do modelo, que é composta por atores, módulos e um banco de dados.

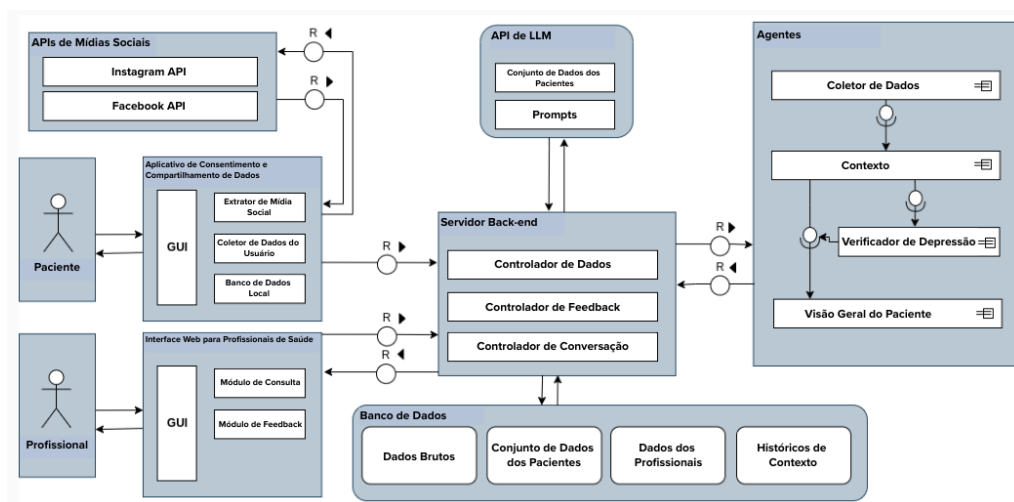


Figura 2. Arquitetura do Modelo

Os principais atores do sistema incluem indivíduos que podem apresentar depressão (Pacientes) e profissionais de saúde mental responsáveis pelo diagnóstico e tratamento (Psicólogos, Psiquiatras e outros profissionais da equipe interdisciplinar). O *Aplicativo de Consentimento e Compartilhamento de Dados* permite ao paciente autorizar a coleta de informações, que são enviadas ao servidor para processamento. Os profissionais de saúde acessam esses dados por meio da *Interface Web para Profissionais de Saúde*, onde podem visualizar as análises geradas e interagir com o sistema.

O aplicativo se comunica diretamente com as *APIs* das redes sociais, intermediando o acesso aos dados de forma compatível com as políticas das plataformas. Após a obtenção do consentimento, o aplicativo troca requisições POST e GET com a *API* da rede social correspondente para recuperar os dados disponíveis. Todas as informações extraídas são enviadas ao *Servidor Backend*, que integra os módulos responsáveis pelo

processamento dos dados, inferências baseadas na ontologia e interação com o banco de dados e a interface do profissional de saúde.

Os dados coletados são armazenados em um banco de dados, incluindo identificação dos pacientes, informações extraídas das redes sociais e registros clínicos adicionados pelos profissionais. Durante o processamento, as postagens das redes sociais passam por análise de sentimentos e técnicas de processamento de texto, sendo organizadas na SPMH. A estrutura respeita a organização por Histórico de Contextos, onde a postagem mais recente é tratada como Contexto Atual, central para a avaliação diagnóstica.

O modelo utiliza um LLM acessível via *API*, capaz de referenciar os critérios diagnósticos descritos no DSM-V-TR e na CID-11 quando solicitado. As informações organizadas na SPMH são utilizadas como entrada para o LLM, que avalia a relevância das postagens, descrevendo os motivos pelos quais determinados conteúdos podem estar associados a traços relevantes de diferentes dimensões clínicas, como comportamento e cognição. Cada análise documenta a origem da informação, indicando quais postagens foram consideradas relevantes e justificando essa classificação, garantindo transparência no processo.

O Servidor *Backend* entrega essa análise aos profissionais de saúde por meio da *Interface Web para Profissionais de Saúde*, que disponibiliza um resumo da avaliação e permite interações via chat. O profissional pode explorar mais detalhes sobre o caso e obter respostas contextualizadas pelo conhecimento do LLM e pelos dados organizados na SPMH. Caso o paciente inicie tratamento, o profissional pode adicionar novas entradas de prontuário ao modelo, como transcrições de sessões e outras informações clínicas. Cada novo dado gerado se torna um novo contexto, mantendo o histórico atualizado e permitindo o acompanhamento contínuo.

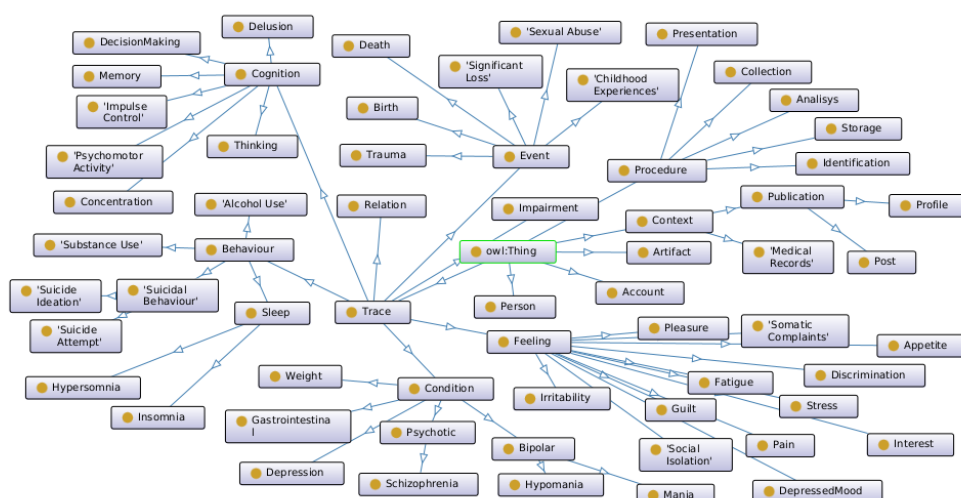
3.3. Ontologia

Arquiteturas direcionadas à inteligência em redes sociais precisam armazenar e organizar os contextos observados para possibilitar análises futuras. No modelo Serapis, a Serapis Personal Mental Health Ontology (SPMH) representa esses contextos, estruturando informações extraídas de redes sociais e registros clínicos para suporte ao diagnóstico e monitoramento de saúde mental.

A SPMH considera cada postagem como um *Contexto*, permitindo sua organização em Históricos de Contexto, que documentam padrões e variações ao longo do tempo. Inspirada em abordagens forenses, a ontologia preserva a integridade dos dados, registrando a origem das informações e garantindo a rastreabilidade dos achados.

A Figura 3 ilustra a estrutura da SPMH, na qual as entidades centrais incluem *Pessoa*, que representa o indivíduo analisado; *Conta*, vinculada às redes sociais utilizadas; *Publicação*, que engloba postagens e atualizações de perfil; e *Traço*, que identifica elementos relevantes no conteúdo analisado. A entidade *Procedimento* registra os métodos empregados na extração e análise das informações, garantindo transparência na geração da inteligência.

A SPMH adota conceitos da ontologia *Friend of a Friend (FOAF)* para estruturar dados sociais e da *Cyber-investigation Analysis Standard Expression (CASE)* para assegurar a confiabilidade das evidências digitais. Além disso, profissionais podem validar



ou complementar os registros, permitindo a evolução contínua do histórico do paciente e aprimorando a precisão das análises geradas pelo modelo.

4. Implementação e avaliação do modelo

As próximas subseções apresentam a implementação de um protótipo, desenvolvido sob o conceito de Mínimo Produto Viável (MVP) do modelo, cocriado com um grupo focal de cinco psicólogos. A avaliação foi conduzida com esses profissionais por meio de feedback qualitativo durante a demonstração do protótipo e da aplicação de um questionário baseado no Modelo de Aceitação da Tecnologia (TAM) [Davis 1989, Marangunić and Granić 2015]. Esta pesquisa foi aprovada pelo Comitê de Ética da Unisinos em setembro de 2024 (CAAE 82040024.3.0000.5344).

4.1. Implementação do MVP

A implementação do MVP seguiu as diretrizes cocriadas no primeiro encontro do grupo focal, priorizando funcionalidades essenciais para viabilizar a avaliação. A Figura 4 ilustra a interface web e o aplicativo móvel desenvolvidos. O aplicativo foi desenvolvido para que pacientes fornecessem seus dados básicos, respondessem ao questionário PHQ-9 e compartilhassem seus dados pessoais da rede Instagram®. Devido à descontinuação de uma *API* da rede Instagram® durante o desenvolvimento, o MVP utilizou arquivos CSV simulando os dados esperados para garantir a continuidade da avaliação.

A aplicação móvel foi desenvolvida como uma *Progressive Web Application* (PWA) utilizando *React Native* e *Expo*, com *TypeScript* para tipagem estática. O fluxo do aplicativo seguiu uma sequência linear de cinco telas: (i) consentimento livre e esclarecido, (ii) preenchimento do formulário com dados básicos e PHQ-9, (iii) tela de integração com redes sociais (simulando a interação), (iv) inserção de senha para criptografia dos dados e (v) tela de conclusão. A criptografia garantiu que somente o paciente definisse quem acessaria as informações coletadas, impedindo que desenvolvedores ou profissionais de saúde tivessem acesso aos dados sem a comunicação explícita da senha.

Desenvolvido em *Python* com *FastAPI*, o *backend* processou os dados e interagiu com a ontologia SPMH. A implementação usou *RDFlib* para manipular a ontologia e

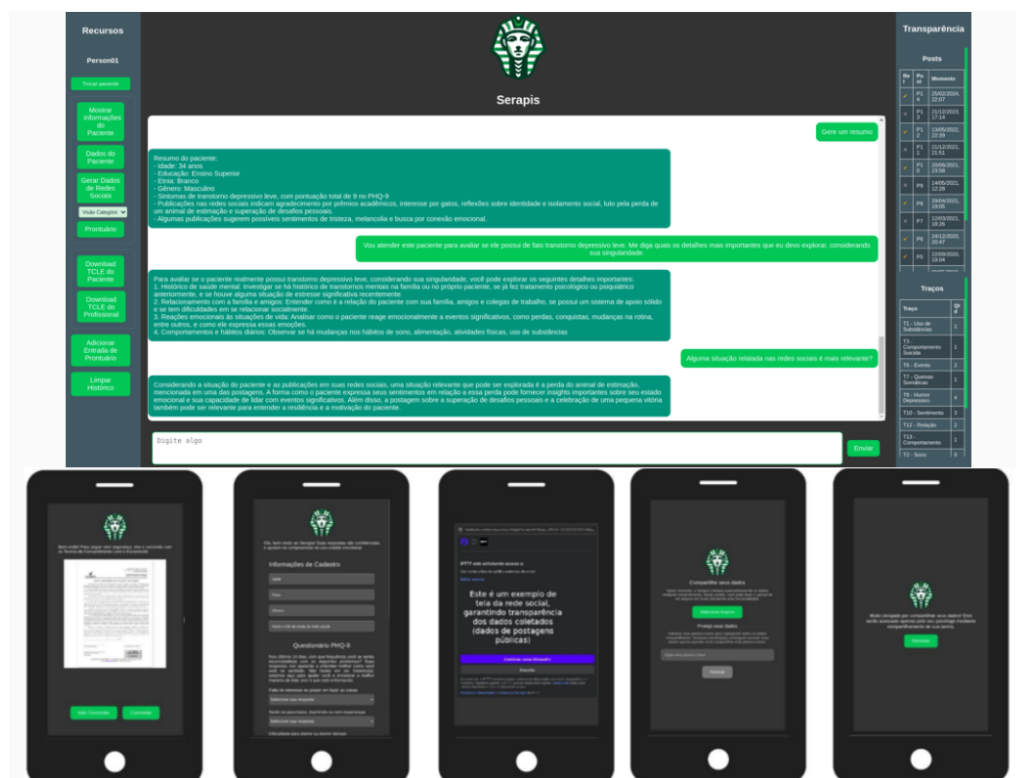


Figura 4. Interface web (acima) e telas do aplicativo móvel (abaixo).

Pandas para organizar os dados recebidos. O sistema estruturou as informações coletadas na SPMH e as armazenou em um arquivo TTL, garantindo modularidade ao MVP sem uso de um banco de dados relacional. Além disso, o *backend* integrou um LLM para análise textual das postagens e inferência de informações contextuais. O processo identificou traços relevantes em postagens individuais e inferiu relações, eventos e características do paciente, como escolaridade, a partir do conjunto de dados analisado.

A interface web, desenvolvida em *React* e *TypeScript*, permitiu que psicólogos acessassem um relatório consolidado dos dados processados. O relatório foi estruturado em três seções: (i) dados do paciente, (ii) resultados do PHQ-9 e (iii) análise das postagens de redes sociais. Essa última seção apresentou as postagens em uma linha do tempo, destacando as consideradas relevantes e exibindo escores de análise de sentimentos, conforme ilustrado na Figura 5. O sistema priorizou a transparência dos dados, permitindo que profissionais explorassem as informações inferidas pelo modelo, verificassem postagens associadas a cada traço identificado e ajustassem as classificações conforme necessário.

4.2. Avaliação do modelo

A avaliação do modelo Serapis ocorreu em duas etapas: (i) um grupo focal para revisão do protótipo e (ii) a aplicação do *Technology Acceptance Model* (TAM) para obter uma avaliação quantitativa da usabilidade e utilidade.

Na sessão do grupo focal, os participantes produziram postagens simuladas, que foram processadas pelo sistema para análise. Essa abordagem permitiu avaliar a identificação de traços relevantes e a inferência de características contextuais. Além da




Figura 5. Visualização de linha do tempo

interface web, foi demonstrada a integração do PHQ-9, evidenciando que o modelo poderia ser aplicado mesmo para pacientes sem redes sociais, utilizando apenas dados estruturados do questionário e registros clínicos. Após a demonstração, psicólogos preencheram um formulário do TAM, avaliando a experiência nas perspectivas de paciente e profissional. A Tabela 2 traz as perguntas da avaliação, organizadas por facilidade de uso e utilidade percebida. As respostas seguiram escala Likert de 5 pontos.

Tabela 2. Formulário de avaliação preenchido pelos terapeutas

ID	Perspectiva	Foco	Afirmações
1	Paciente	Facilidade de Uso	Eu me sentiria confortável em compartilhar informações pessoais e dados no aplicativo.
2	Paciente	Facilidade de Uso	Usar o aplicativo é confortável e não me sinto pressionado a responder ao questionário ou fornecer dados.
3	Paciente	Facilidade de Uso	Senti-me encorajado a fornecer respostas honestas no questionário sem medo de julgamento.
4	Paciente	Facilidade de Uso	As perguntas do questionário sobre meu estado psicológico são fáceis de entender.
5	Paciente	Utilidade	As perguntas do questionário refletem com precisão meus pensamentos e sentimentos.
6	Paciente	Utilidade	A flexibilidade para responder ao questionário e compartilhar dados a qualquer momento é útil.
7	Profissional	Facilidade de Uso	A interface do chatbot parece permitir uma exploração fácil e simples das informações.
8	Profissional	Facilidade de Uso	Sinto-me confortável usando o chatbot como assistente no processo diagnóstico.
9	Profissional	Facilidade de Uso	O chatbot parece fácil de usar.
10	Profissional	Utilidade	As informações fornecidas pelo modelo parecem úteis para o processo diagnóstico.
11	Profissional	Utilidade	Sinto-me mais confiante na minha avaliação ao final do processo diagnóstico ao usar essa ferramenta.
12	Profissional	Utilidade	Senti confiança nas informações fornecidas pelo modelo.
13	Profissional	Utilidade	Acredito que o uso do chatbot aumentaria minha produtividade.
14	Profissional	Utilidade	Eu usaria regularmente o chatbot nos processos de diagnóstico da depressão.

Essa abordagem permitiu coletar impressões qualitativas sobre o funcionamento do modelo e obter dados estruturados para análise quantitativa. A combinação dessas técnicas garantiu uma avaliação abrangente, considerando tanto a experiência de interação

com a ferramenta quanto sua aplicabilidade prática em diferentes cenários clínicos.

5. Resultados

A Figura 6 apresenta os dados quantitativos obtidos pelo TAM, que revelaram boa aceitação do modelo Serapis tanto na perspectiva do paciente quanto na do profissional. No geral, as avaliações de facilidade de uso (itens 1 a 4 e 7 a 9) mostraram concordância positiva, indicando conforto e clareza na interação com o sistema. Houve apenas um caso de neutralidade acerca do quão confortável seria responder ao questionário, sugerindo que há espaço para aprimorar a experiência do usuário.

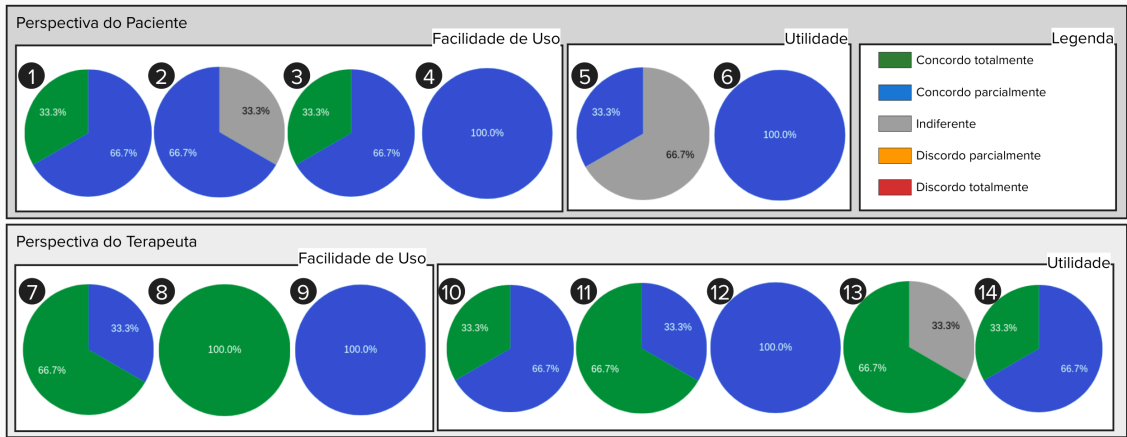


Figura 6. Resultados do TAM nas perspectivas de paciente e profissional

Quanto à utilidade percebida (itens 5, 6 e 10 a 14), os participantes destacaram que a plataforma agrega valor ao processo clínico, aumentando a confiança na tomada de decisão e oferecendo flexibilidade ao paciente. Entretanto, emergiram divergências pontuais sobre a adequação do PHQ-9, indicando a possibilidade de substituí-lo por outro instrumento psicométrico mais alinhado às necessidades específicas, em vez de reformular o questionário existente.

Os resultados qualitativos do grupo focal reforçaram esses achados. Entre as sugestões, destaca-se a permissão para que o paciente compartilhe conteúdos adicionais (como anotações pessoais), ampliando a visão clínica sem comprometer a autonomia. Se evidenciou a importância de garantir segurança e transparência no uso de IA generativa, preservando a atuação profissional como elemento central na interpretação dos dados.

Em síntese, tanto os dados do TAM quanto as impressões coletadas no grupo focal sugerem que o Serapis possui potencial para apoiar o diagnóstico e o acompanhamento de depressão. Apesar da boa aceitação geral, foram identificadas oportunidades de melhoria, sobretudo na adoção de instrumentos psicométricos mais apropriados e no aperfeiçoamento das funcionalidades de compartilhamento de informações, visando aperfeiçoar ainda mais a eficácia e a experiência de uso da solução.

6. Conclusão

Este trabalho apresentou o Serapis, um modelo computacional que preenche a lacuna de integrar dados de redes sociais e registros clínicos em uma ontologia (SPMH), suprimindo a limitação de abordagens que se baseiam apenas em autodeclarações ou questionários

isolados para o diagnóstico de depressão. Essa integração garante rastreabilidade e transparência na análise, oferecendo aos profissionais uma visão contextualizada do estado mental do paciente, sem substituir sua expertise no processo diagnóstico e terapêutico.

O MVP desenvolvido foi avaliado em um grupo focal de psicólogos e por meio do TAM, confirmando alta facilidade de uso e utilidade percebida. Ainda assim, o uso de dados simulados e o número reduzido de participantes restringiram a avaliação em cenários reais. Entre as recomendações, destacou-se a necessidade de permitir que o paciente compartilhe conteúdos adicionais, como anotações pessoais, ampliando a visão clínica sem comprometer sua autonomia. Além disso, a criptografia foi apontada como um elemento central para garantir a privacidade dos dados, reforçando o compromisso do modelo com a segurança da informação.

Como pesquisas futuras, propõe-se expandir a aplicação para outros transtornos mentais, integrar dados de diferentes plataformas sociais e habilitar um monitoramento contínuo do paciente. Esses aprimoramentos podem consolidar o Serapis como uma ferramenta robusta para o suporte a diagnósticos mais eficazes e um acompanhamento terapêutico mais personalizado, mantendo o profissional no centro do processo e assegurando o controle do paciente sobre seus dados.

Agradecimentos

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) – Código de Financiamento 001, e à Universidade do Vale do Rio dos Sinos (Unisinos) pelo apoio ao desenvolvimento deste trabalho.

Referências

- Allen, S. (2020). Artificial intelligence and the future of psychiatry. *IEEE Pulse*, 11(3):2–6.
- APA (2022). Diagnostic And Statistical Manual Of Mental Disorders, Fifth Edition, Text Revision (DSM-5-TR). <https://dsm.psychiatryonline.org/doi/book/10.1176/appi.books.9780890425787>.
- Böhm, I. and Lolagar, S. (2021). Open source intelligence: Introduction, legal, and ethical considerations. *International Cybersecurity Law Review*, 2(2):317–337.
- Chen, L., Magdy, W., Whalley, H., and Wolters, M. K. (2020). *Examining the Role of Mood Patterns in Predicting Self-Reported Depressive Symptoms*, page 164–173. Association for Computing Machinery, New York, NY, USA.
- Davis, F. D. (1989). Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS Quarterly: Management Information Systems*, 13(3):319–339.
- Ebner-Priemer, U. W., Mühlbauer, E., Neubauer, A. B., Hill, H., Beier, F., Santangelo, P. S., Ritter, P., Kleindienst, N., Bauer, M., Schmiedek, F., and Severus, E. (2020). Digital phenotyping: towards replicable findings with comprehensive assessments and integrative models in bipolar disorders. *International Journal of Bipolar Disorders*, 8(1).

- Heckler, W. F., Carvalho, J. V. d., and Barbosa, J. L. V. (2022). Machine learning for suicidal ideation identification: A systematic literature review. *Computers in Human Behavior*, 132:107095.
- Heckler, W. F., Feijó, L. P., Carvalho, J. V., and Barbosa, J. L. V. (2023). Thoth: An intelligent model for assisting individuals with suicidal ideation. *Expert Systems with Applications*, 233:120918.
- Islam, M. R., Kabir, M. A., Ahmed, A., Kamal, A. R. M., Wang, H., and Ulhaq, A. (2018). Depression detection from social network data using machine learning techniques. *Health Inf. Sci. Syst.*, 6(1):8.
- Jain, V., Chandel, D., Garg, P., and Vishwakarma, D. K. (2020). Depression and impaired mental health analysis from social media platforms using predictive modelling techniques. In *2020 Fourth International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC)*, pages 855–860.
- Larsen, O. H. (2022). Open source intelligence techniques: A quantitative study of the norwegian police university college students use of osint techniques in their online investigations through their year of practical training.
- Manikonda, L. and De Choudhury, M. (2017). Modeling and understanding visual attributes of mental health disclosures in social media. In *Proceedings of the 2017 CHI Conference on Human Factors in Computing Systems*, CHI '17, page 170–181, New York, NY, USA. Association for Computing Machinery.
- Marangunić, N. and Granić, A. (2015). Technology acceptance model: a literature review from 1986 to 2013. *Universal Access in the Information Society*, 14(1):81–95.
- Ricard, B. J., Marsch, L. A., Crosier, B., and Hassanpour, S. (2018). Exploring the utility of community-generated social media content for detecting depression: An analytical study on instagram. *J Med Internet Res*, 20(12):e11817.
- SAP (2007). Standardized Technical Architecture Modeling: conceptual and design level.
- Schaurer, F. and Störger, J. (2013). The evolution of open source intelligence (osint). *Comput Hum Behav*, 19:53–56.
- Seabrook, E. M., Kern, M. L., Fulcher, B. D., and Rickard, N. S. (2018). Predicting depression from language-based emotion dynamics: Longitudinal analysis of facebook and twitter status updates. *J Med Internet Res*, 20(5):e168.
- WHO (2022). World mental health report: Transforming mental health for all - executive summary. <https://www.who.int/publications/i/item/9789240050860>. World Health Organization.
- Wongkoblap, A., Vadillo, M. A., and Curcin, V. (2019). Predicting social network users with depression from simulated temporal data. In *IEEE EUROCON 2019 -18th International Conference on Smart Technologies*, pages 1–6.
- Yang, X., McEwen, R., Ong, L. R., and Zihayat, M. (2020). A big data analytics framework for detecting user-level depression from social networks. *International Journal of Information Management*, 54:102141.