

Desenvolvimento de uma tecnologia baseada em inteligência artificial para identificação de depressão em acadêmicos

Development of an Artificial Intelligence-Based technology for identifying Depression in Academic

Desarrollo de una tecnología basada en Inteligencia Artificial para la identificación de la Depresión en Académicos

Júlio Gonçalves¹, Ramon Tomaz¹, Adriana Gomes Alves¹

¹ Universidade do Vale do Itajaí (UNIVALI), Mestrado Profissional em Psicologia – Itajaí – Santa Catarina – Brasil.

RESUMO

A revolução digital tem impactado significativamente as práticas de saúde, incluindo a saúde mental, com o uso de inteligência artificial (IA), *big data* e tecnologias de neuroimagem. Este estudo visa propor uma tecnologia digital baseada em IA para identificar sintomas de depressão em acadêmicos, focando na adaptação e na validação de instrumentos psicométricos para essa população. Seguiu-se um fluxo iterativo e uma estrutura conceitual adaptada. Foram realizadas revisões de literatura e coleta de dados com acadêmicos. A adaptação dos instrumentos envolveu avaliações semânticas e de conteúdo, utilizando o Coeficiente de Validade de Conteúdo (CVC) e o Patient Health Questionnaire-9 (PHQ-9). A Entrevista para Depressão Centrada em Acadêmicos (EDCA-12) apresentou um escore geral de CVCt de 0,89 e um alfa de Cronbach de 0,95. O modelo *Logistic Regression* (LR) alcançou uma precisão de 97% na identificação de sintomas de depressão. A tecnologia desenvolvida demonstrou potencial na avaliação de depressão em acadêmicos. Futuros estudos devem aprimorar a interface do usuário e expandir a validação empírica para diferentes contextos.

Palavras-chave: Depressão. Estudantes. Inteligência artificial.

ABSTRACT

The digital revolution has significantly impacted health practices, including mental health, through the use of Artificial Intelligence (AI), big data, and neuroimaging technologies. This study aims to propose a digital technology based on AI to identify symptoms of depression in academics, focusing on the adaptation and validation of psychometric instruments for this population. An iterative flow and an adapted conceptual framework were followed. Literature reviews and data collection with academics were conducted. The adaptation of the instruments involved semantic and content evaluations using the Content Validity Coefficient (CVC) and the PHQ-9. The Interview for Depression Centered on Academics (EDCA-12) presented an overall CVCt score of 0.89 and a Cronbachs alpha of 0.95. The Logistic Regression (LR) model achieved 97% accuracy in identifying depression symptoms. The developed technology demonstrated potential in assessing depression in academics. Future studies should enhance the user interface and expand empirical validation to different contexts.

Keywords: Machine Learning. Depression. Students.

Correspondência:

Júlio Gonçalves

E-mail: contato@psicojulio.com | julio.pinho@unifebe.edu.br



RESUMEN

La revolución digital ha impactado significativamente las prácticas de salud, incluida la salud mental, mediante el uso de Inteligencia Artificial (IA), big data y tecnologías de neuroimagen. Este estudio tiene como objetivo proponer una tecnología digital basada en IA para identificar síntomas de depresión en académicos, centrándose en la adaptación y validación de instrumentos psicométricos para esta población. Se siguió un flujo iterativo y un marco conceptual adaptado. Se realizaron revisiones de literatura y recolección de datos con académicos. La adaptación de los instrumentos involucró evaluaciones semánticas y de contenido, utilizando el Coeficiente de Validez de Contenido (CVC) y el PHQ-9. La Entrevista para la Depresión Centrada en Académicos (EDCA-12) presentó una puntuación general de CVCT de 0,89 y un alfa de Cronbach de 0,95. El modelo de Regresión Logística (LR) alcanzó una precisión del 97% en la identificación de síntomas de depresión. La tecnología desarrollada demostró potencial en la evaluación de la depresión en académicos. Futuros estudios deben mejorar la interfaz de usuario y ampliar la validación empírica para diferentes contextos.

Palabras clave: Depresión. Estudiantes. Inteligencia Artificial.

Destaques clínicos

- O estudo desenvolveu e validou uma tecnologia baseada em inteligência artificial (IA) para identificar fatores de risco e proteção de depressão em acadêmicos. A tecnologia utiliza algoritmos de aprendizado de máquina supervisionado para analisar dados coletados a partir de uma entrevista psicométrica adaptada para o público acadêmico.
- Os resultados indicam que a IA pode melhorar a precisão na triagem de sintomas depressivos, fornecendo suporte na identificação precoce e no encaminhamento adequado para intervenção clínica.
- A aplicação da ferramenta pode otimizar a prática clínica em terapia cognitivo-comportamental (TCC), possibilitando avaliações mais rápidas e baseadas em evidências.

A revolução digital tem alterado as práticas em saúde de forma massiva, de maneira que a detecção inteligente, análise de *big data*, inteligência artificial (IA), computação em nuvem, controle automático e execução autônoma e robótica já compõem a rotina da prática profissional em saúde há alguns anos (Lottemberg *et al.*, 2019). Do mesmo modo, nas rotinas de profissionais da saúde mental, o uso de *smartphones*, *wearables*, neuroimagem e mídias sociais contribuem para os atendimentos clínicos e para as pesquisas, por meio da produção e do acesso a uma grande quantidade de dados (Renn *et al.*, 2021).

A IA compõe o quadro de tecnologias que justificam a Revolução Digital, com seu início em 1950, a partir da união de vários cientistas, matemáticos e filósofos, dando início às discussões sobre a criação de máquinas que simulam o comportamento humano (Graham *et al.*, 2019; Lottemberg *et al.*, 2019). Atualmente, a pesquisa, o ensino e o desenvolvimento de IA continuam em gradativa expansão, e seu principal objetivo é tornar os equipamentos úteis por meio de ferramentas que apoiam e facilitam as atividades intelectuais das mais diversas áreas (Kusters *et al.*, 2020). Em termos de benefícios e oportunidades, a IA se estende a várias áreas, como acessibilidade (p. ex., aplicativos para deficiência visual e transtorno do espectro autista), agricultura e meio ambiente (p. ex., análise de regiões agrícolas), transporte (p. ex., carros autônomos), saúde (p. ex., diagnóstico), entre outras (Dwivedi *et al.*, 2019).

Acerca das áreas da saúde, principalmente na medicina, abordagens baseadas em IA têm se inserido de modo prevalente, em oposição à saúde mental em específico, com inserção em menor velocidade (Graham *et al.*, 2019). Isso porque psicólogos e psiquiatras são centrados no paciente em sua prática clínica, com maior enfoque na relação terapêutica e na observação direta dos comportamentos, emoções e cognições. Essa forma de prática clínica faz uso de declarações qualitativas e registros escritos do paciente por meio de notas clínicas, formulários e questionários (Gonçalves, 2023).

Contudo, apesar de incipiente, as tentativas de inserção da IA na saúde mental têm revelado resultados promissores. Um exemplo disso é a Cass (<https://www.x2ai.com/>), mantida por uma combinação de tecnologias e técnicas de aprendizagem de máquina que oferece intervenções de saúde mental para reduzir os sintomas de depressão e de ansiedade (Fulmer *et al.*, 2018). Na interação com Tess, os sujeitos realizam registros diários de comportamentos e emoções, de modo que as orientações fornecidas pelo *chatbot*, com base nesses registros, se originam de diversas abordagens psicológicas, como terapia cognitivo-comportamental (TCC), terapia baseada em *mindfulness*, terapia focada nas emoções (TFE), terapia de aceitação e compromisso (ACT), terapia da autocompaixão e psicoterapia interpessoal.

Os resultados de um estudo (Fulmer *et al.*, 2018), com 74 participantes que receberam acesso ilimitado à Tess,

revelaram uma diferença estatisticamente significativa entre o grupo-controle e o grupo experimental, de modo que o grupo experimental apresentou uma redução significativa nos sintomas de depressão medidos pelo Patient Health Questionnaire-9 (PHQ-9) ($p = 0,03$).

Em outro estudo piloto, a ADA (c2025) foi desenvolvida com o objetivo de gerar hipóteses diagnósticas (Jungmann et al., 2019). O aplicativo tem a dupla finalidade de autoavaliação pelo próprio usuário ou avaliação de apoio à decisão diagnóstica por profissionais da saúde. O *chatbot* solicita os sintomas na forma de anamnese médica, em uma escala dicotômica (sim ou não), e seus resultados são gerados com base em um banco de dados médicos. Os achados iniciais do estudo piloto, no que se refere à qualidade diagnóstica fornecida pela ADA (c2025), evidenciam uma concordância moderada ($\kappa = 0,78$) entre psicoterapeutas que utilizaram o aplicativo para geração de diagnósticos psicopatológicos em adultos.

Ainda, as revisões recentes conduzidas por Graham et al. (2019) e Sijia et al. (2022) destacam efeitos benéficos na prática clínica em saúde mental, principalmente na identificação e na detecção de transtornos mentais, com destaque para o transtorno depressivo maior (TDM). Tais dados são congruentes com a revisão sistemática conduzida por Gonçalves e Alves (no prelo), com o objetivo de verificar o *status* das pesquisas sobre IA no TDM. A revisão revelou que tecnologias baseadas em IA se dividem em três domínios de aplicação: detecção diagnóstica do TDM ($n = 17$), discriminação do TDM entre outros transtornos mentais ($n = 5$) e previsão da eficácia do tratamento no TDM ($n = 4$). Acerca dos instrumentos utilizados, destacam-se entrevistas clínicas e escalas psicométricas (p. ex., Hamilton Depression Rating Scale) e equipamentos (p. ex., eletroencefalograma), de modo que a maioria dos estudos fez uso de dados neuroanatômicos ($n = 16$), especificamente, imagens de ressonância magnética.

Apesar das potenciais aplicações, uma limitação comum nos estudos é a utilização de dados restritos a códigos e notas psiquiátricas, focados em sintomas específicos do TDM descritos nos manuais diagnósticos (Nemesure et al., 2021). Em síntese, essa revisão revela uma lacuna significativa no uso de IA aplicada ao TDM, caracterizada pelo enfoque excessivo na sintomatologia (p. ex., respostas fisiológicas, emocionais, ativação de áreas encefálicas) e pela exclusão de variáveis essenciais para sua identificação, como fatores hereditários, exposição a adversidades, padrões de personalidade, alterações hormonais e maturacionais, problemas familiares, hábitos de vida e aspectos psicossociais. Tais fatores transcendem classificações baseadas exclusivamente em imagens ou instrumentos generalistas de sintomas e saúde global (Flesch et al., 2020; Sheldon et al., 2021).

A escolha do público-alvo deste estudo foi feita por conta da alta prevalência de TDM entre acadêmicos, conforme destacado pelo Fórum Nacional de Pró-Reitores de Assuntos Comunitários e Estudantis ([FONAPRACE], 2016).

O levantamento, realizado com uma amostra de 939.604 estudantes de Instituições Federais de Ensino Superior, revelou que 79,8% ($n = 794.804$) relataram dificuldades emocionais nos últimos 12 meses.

As pesquisas destacam diversos fatores de risco associados ao desenvolvimento de depressão em acadêmicos, abrangendo dimensões contextuais e individuais.

1. Práticas parentais e experiências traumáticas: estudos mostram que negligência parental e estresse precoce aumentam o risco de psicopatologias na vida adulta. Separação dos pais, assédio sexual e depressão parental predis põem à depressão e ao suicídio (Mello et al., 2009; Weber & Natalia, 2017; Sheldon et al., 2021).
2. Estilo cognitivo: atribuições negativas, viés de memória, ruminação e autoimagem distorcida aumentam a vulnerabilidade à depressão. Acadêmicos com estilos cognitivos negativos têm maior probabilidade de desenvolver depressão (Alloy et al., 2000; Mathews & MacLeod, 2005).
3. Autoeficácia acadêmica: baixa percepção de autoeficácia está associada a ingresso na universidade e desempenho acadêmico ruins, aumentando a chance de depressão (Cerchiari et al., 2005; Flesch et al., 2020).
4. Expressão e regulação emocional: déficits no processamento cognitivo afetam a capacidade de regular emoções, intensificando vulnerabilidades para transtornos mentais. A dificuldade em inibir pensamentos negativos é diretamente ligada à regulação emocional prejudicada (Gotlib & Joormann, 2010).
5. Relacionamentos interpessoais: sentimentos de solidão e dificuldades de adaptação a moradias compartilhadas aumentam a prevalência de depressão em acadêmicos (Flesch et al., 2020; McClelland et al., 2020; Ribeiro et al., 2020).
6. Estratégias de aprendizagem: estratégias baseadas em evitação experiencial têm correlações significativas com depressão, estresse e ansiedade, evidenciando a relação entre evitação acadêmica e sofrimento emocional (Zancan et al., 2021).
7. Integração acadêmica: alunos insatisfeitos com o curso ou não integrados à instituição têm risco quase quatro vezes maior de depressão, especialmente quando somado a problemas familiares, problemas sociais e ausência de atividade física (Leão et al., 2018).

Dessa maneira, com base nas seguintes justificativas: 1) a lenta inserção da IA na área da saúde mental (Graham et al., 2019); 2) os resultados promissores, embora incipientes, da aplicação de IA na saúde mental (Sijia et al., 2022); e 3) a escassez de estratégias avaliativas do TDM que considerem as dimensões contextuais e vivenciais dos acadêmicos (Paetzold et al., 2021), a presente pesquisa propõe descrever o desenvolvimento de uma tecnologia baseada em IA para identificar sintomas de depressão em acadêmicos, integrando

fatores contextuais e específicos desse público. Como objetivos específicos, pretende-se: a) desenvolver e adaptar uma entrevista para coleta de dados que contemple as dimensões contextuais e vivenciais dos acadêmicos; b) realizar a validação de conteúdo do instrumento, envolvendo juízes especialistas e a população-alvo; e c) avaliar a precisão e o desempenho dos modelos de aprendizado de máquina implementados na previsão de sintomas de depressão em acadêmicos, com base nas dimensões contextuais, vivenciais e sintomatológicas apresentadas.

METODOLOGIA

A construção e a validação da entrevista foram aprovadas pelo Comitê de Ética em Pesquisa da Universidade do Vale do Itajaí (UNIVALI), sob parecer substanciado nº 5.318.679 e Certificado de Apresentação de Apreciação Ética nº 53149921.2.0000.0120.

O projeto foi organizado por meio da sobreposição e adaptação de duas abordagens: o fluxo iterativo baseado em Pressman e Maxim (2021) e a estrutura conceitual utilizada por Tao et al. (2021). As etapas do projeto incluem: a) adaptação de instrumentos; b) transferência do conhecimento; c) processamento de dados; d) modelagem; e e) entrega. A principal característica do fluxo iterativo é o diálogo permanente entre os desenvolvedores, o projeto e o público, garantindo refinamento e revisões contínuas em cada etapa da estrutura conceitual, realizadas no modo “cascata,” conforme ilustrado na Figura 1.

NATUREZA

Esta pesquisa é de natureza aplicada e descritiva, com abordagens qualitativa e quantitativa. Ela é classificada como

aplicada devido à intenção de desenvolver uma solução prática por meio da construção de uma entrevista e uma aplicação baseada em técnicas de IA. Também é descritiva por especificar características e descrever tendências psicológicas em um grupo de acadêmicos. O enfoque qualitativo se dá pela avaliação semântica dos juízes especialistas e da população-alvo, e o quantitativo, pela coleta de dados fundamentada na medição e na estatística descritiva para avaliação da concordância entre os juízes especialistas (Sampieri et al., 2013).

CARACTERÍSTICAS DA AMOSTRA

Participaram deste estudo seis juízes especialistas (Lynn, 1986), quatro homens e duas mulheres, com idade média de 31 anos ($DP = 3,3$ anos), sendo que 83,3% ($n = 5$) tinham mestrado completo e 16,7% ($n = 1$), doutorado completo. A amostra foi selecionada com base na técnica de amostragem não probabilística por conveniência do tipo *snowball sampling*, incluídos a partir de critérios que somaram no mínimo quatro pontos (Moura et al., 2019).

Para a validação semântica do conteúdo, participaram 10 acadêmicos da população-alvo (Cunha et al., 2018), quatro homens e seis mulheres, com idade média de 22,3 anos ($DP = 1,9$ anos). Para a pré-testagem do instrumento, foram coletados dados de 60 acadêmicos, sendo 73,3% mulheres ($n = 44$), 23,3% homens ($n = 14$) e 3,3% não binários ($n = 2$), com idade média de 27,8 anos ($DP = 8,78$). A amostra foi selecionada com base na técnica de amostragem não probabilística por conveniência do tipo intencional (Sampieri et al., 2013), sem randomização. A base de dados resultante inclui dados desses 60 acadêmicos, abrangendo 21 atributos que variam entre variáveis ordinais, binárias e contínuas, coletados entre maio e julho de 2022.




Figura 1. Organização do projeto e implementação da inteligência artificial.

INSTRUMENTOS

Para avaliação dos itens pelos juízes especialistas, foi desenvolvida uma ficha para verificação do Coeficiente de Validade de Conteúdo (CVC). Foram considerados os seguintes critérios: comportamental, objetividade, simplicidade, clareza, relevância, precisão, variedade, modalidade, tipicidade e credibilidade (Pasquali, 2024).

Já os desfechos de interesse, que são os níveis de depressão, foram estabelecidos a partir do Patient Health Questionnaire-9 (PHQ-9), um questionário de autorrelato de nove itens que avalia a frequência e a gravidade dos sintomas de depressão nas duas semanas anteriores. Os itens são baseados nos critérios da 5ª edição do *Manual diagnóstico e estatístico de transtornos mentais* (DSM-5) para TDM e são pontuados em uma escala de 0 (nada) a 3 (quase todos os dias). O PHQ-9 é amplamente utilizado, confiável e validado (Santos et al., 2013).

PROCEDIMENTOS PARA COLETA DE DADOS

A adaptação da entrevista seguiu os princípios de construção de instrumentos psicométricos citados por Pasquali (2024). As etapas incluem: polo teórico, polo empírico e polo experimental.

Para a execução do polo teórico, foram utilizados os modelos propostos por Almeida et al. (2001) e Polydoro et al. (2001), seccionados nos seguintes atributos: ajustamento psicológico, ajustamento social, ajustamento acadêmico e ajustamento vocacional. Para justificar os fatores extraídos, foram realizadas revisões da literatura em bases de dados eletrônicas (PubMed, PsycINFO, SciELO, Web of Science, Scopus e Biblioteca Virtual em Saúde). Literatura clássica e baseada no objeto psicológico também serviram como fontes de informação (Pasquali, 2024).

As etapas dos polos empírico e experimental foram divididas em três testes pilotos (TP1, TP2 e TP3). No TP1, foi realizada a avaliação da concordância entre juízes especialistas, os quais foram orientados por *e-mail*, de forma individual, e receberam a ficha para o CVC organizada em escala Likert com pontuação de 1 a 4, com o objetivo de avaliar a representatividade dos itens. Assim, 1 = “não relevante ou não representativo”; 2 = “item necessita de grande revisão para ser representativo”; 3 = “item necessita de pequena revisão para ser representativo”; e 4 = “item relevante ou representativo”. Para a avaliação semântica, ao final de cada item constava um espaço em branco para inserção de comentários e observações acerca do item (Gorenstein & Wang, 2024).

Para o TP2, de avaliação semântica da população-alvo, uma versão preliminar do instrumento, com um espaço em branco ao lado de cada item para inserção de comentários e observações, foi enviada por *e-mail* de forma individual a 10 acadêmicos matriculados em Instituições de Ensino Superior no Brasil. Os acadêmicos avaliaram se a formulação e a apresentação das questões ofereciam dificuldade conceitual,

tempo médio de resposta e percepção de clareza dos itens (Cunha et al., 2018; Pasquali, 2024).

Por fim, após as correções coletadas via TP1 e TP2, no polo experimental e TP3, a versão final da entrevista foi aplicada em acadêmicos em conjunto com o PHQ-9 (avaliação da depressão), sendo coletados 60 conjuntos de respostas, que foram utilizados como dados de treinamento para o desenvolvimento de uma tecnologia digital baseada em IA.

ANÁLISE DOS DADOS

O nível de concordância foi avaliado pelo CVC. Foram calculados CVC para cada item (CVCi) e CVC total (CVCt), com base nos critérios comportamental, objetividade, simplicidade, clareza, relevância, precisão, variedade, modalidade, tipicidade e credibilidade. Para que o CVCi seja considerado confiável, o valor mínimo é de 0,78 e maior que 0,80 para o CVCt, com um alfa de Cronbach mínimo de 0,70 (Yusoff, 2019).

Para a etapa de modelagem, foi utilizada a abordagem de aprendizado de máquina supervisionado, na qual os dados são rotulados e supervisionados para treinar modelos, permitindo prever resultados para dados não rotulados. Sustentada pela lógica indutiva, o modelo supervisionado prevê uma variável dependente (p. ex., depressão ou não) a partir de variáveis independentes (p. ex., tipo de humor, nível de atividade física) (Presotto, 2021).

Os testes foram realizados utilizando *Logistic Regression* (LR), *Linear Discriminant Analysis* (LDA), *K-Neighbors Classifier* (KNN), *Decision Tree Classifier* (CART), *Gaussian Naive Bayes* (NB) e *Support Vector Machine* (SVM), implementados na linguagem Python por meio de bibliotecas típicas para análises de dados, como Pandas, Numpy e Sci-Kit. A técnica de validação cruzada, que avalia a capacidade de generalização do modelo a partir de um conjunto de dados, foi aplicada utilizando o método *Hold-out* (Garnier et al., 2022). Nessa técnica, 80% dos dados foram utilizados para treinamento e 20%, para teste, garantindo uma avaliação robusta do desempenho do modelo.

As entradas consistiram no *corpus* qualificado de textos e números extraídos da entrevista adaptada, enquanto as saídas foram classificadas como “não clínico”, “depressão leve”, “depressão moderada” e “depressão severa”. Cada modelo foi avaliado com base em métricas de precisão, *recall* e F1-score para determinar sua eficácia.

RESULTADOS

A seguir, são descritos os procedimentos de desenvolvimento da IA baseadas no fluxo iterativo de Pressman e Maxim (2021) e a estrutura conceitual de Tao et al. (2021).

ADAPTAÇÃO DO INSTRUMENTO

Na etapa de procedimento teórico, a primeira versão do instrumento foi nomeada Entrevista para Depressão Centrada em Acadêmicos (EDCA-12) e apresentou 12 itens abertos, tratada como instrumento piloto, como pode ser observado no Quadro 1.

No polo empírico, em relação ao índice de concordância entre os juízes especialistas, para os dez critérios julgados – comportamental, objetividade, simplicidade, clareza, relevância,

precisão, variedade, modalidade, tipicidade e credibilidade – foi obtido um escore geral (CVCt) de 0,89, considerado instrumento confiável (Filgueiras *et al.*, 2015). Quanto à confiabilidade e à

Quadro 1. Distribuição dos itens por fatores e bases teóricas.

FATORES	BASES TEÓRICAS	ITEM DA ENTREVISTA
PSICOLÓGICO		
Desenvolvimento humano (itens 1a, 1b e 2)	Weber <i>et al.</i> (2017) Mello <i>et al.</i> (2009) Sheldon <i>et al.</i> (2021)	1a. As figuras parentais (pai, mãe, avós, avôs, cuidadores, etc.) são muito relevantes para o nosso desenvolvimento, afinal, normalmente são essas figuras que convivem conosco grande parte de nossa vida. Que figura parental você julga ter sido a mais marcante no seu desenvolvimento (negativa e/ou positivamente)? 1b. Como você descreveria o seu relacionamento (problemas e/ou afetos) com essa pessoa?
Estilo cognitivo (itens 3a, 3b e 3c)	Alloy <i>et al.</i> (2000) Mathews <i>et al.</i> (2005)	2. Às vezes acontecem coisas extremamente perturbadoras às pessoas (p. ex., de ameaça, à vida, um desastre, um acidente muito grave, ser agredido física ou sexualmente, ver alguém ferido ou hospitalizado, etc.). Caso algo dessa natureza tenha acontecido com você, em algum momento durante a sua vida, me relate brevemente. 3a. Se você pudesse resumir em palavras como você se vê como pessoa, que palavras seriam essas? 3b. Se você pudesse resumir em palavras como vê as pessoas ao seu redor, que palavras seriam essas? 3c. Se você pudesse resumir em palavras como vê o seu futuro, que palavras seriam essas?
Expressão emocional (itens 4, 5a e 5b)	Gotlib <i>et al.</i> (2010)	4. O estado de humor é uma parte importante da nossa vida e ela se caracteriza pela disposição, pelo estado de espírito e pelos sentimentos que mantemos ao longo dos dias. Como você descreve seu humor nas últimas duas semanas? 5a. Você tem percebido alguma alteração no seu interesse por atividades de que gosta (p. ex., gostava de determinados passatempos e tem se sentido desanimado(a) para realizá-los)? 5b. Se sim, há quantos dias (em média) não está realizando essas atividades?
SOCIAL		
Relacionamento interpessoal (itens 6 e 7)	Ribeiro <i>et al.</i> (2020) McClelland <i>et al.</i> (2020) Flesch <i>et al.</i> (2020)	6. Sobre suas relações sociais, com que frequência (em média) você interage presencialmente com pessoas importantes para você (p. ex., parentes, amigos, etc.) em uma semana usual? 7. Ainda sobre suas relações sociais, como você descreveria seu convívio com os pares (amigos, colegas de quarto, colegas de faculdade etc.)?
ACADÊMICO		
Hábitos de vida (itens 8a, 8b, 8c e 9)	Lev-Ran <i>et al.</i> (2014) Vieira <i>et al.</i> (2021) Pedrelli <i>et al.</i> (2016)	8a. Você faz uso de bebida alcoólica, maconha, cigarros ou outras substâncias psicoativas? 8b. Se sim, qual(is) substância(s) você faz uso? 8c. Qual a frequência semanal (em média) que você faz uso dessas substâncias psicoativas? 9. Com que frequência (em média) você faz atividades físicas na semana (academia, corrida, bicicleta, caminhada, etc.)?
Autorregulação aprendizagem (item 10)	Zancan <i>et al.</i> (2021)	10. Como você age (ou agiria, caso não tenha passado por isso) quando se depara com uma grande quantidade de trabalhos e atividades acadêmicas a serem feitas?
Autoeficácia acadêmica (item 11)	Cerchiari <i>et al.</i> (2005) Flesch <i>et al.</i> (2020)	11. Descreva como você se vê em termos de desempenho na faculdade (como são suas habilidades e competências acadêmicas, seus conhecimentos, etc.).
VOCACIONAL		
Integração com a instituição (item 12)	Leão <i>et al.</i> (2018)	12. Descreva as satisfações e/ou insatisfações com o seu curso.

consistência interna, um alfa de Cronbach significativo de 0,95 foi verificado.

Os critérios com maiores índices de concordância foram credibilidade (0,99), modalidade (0,97), comportamento (0,96), clareza (0,94) e simplicidade (0,90), destacando o quanto o instrumento transmite seriedade, permite respostas diretas e representa ações precisas com itens simples e claros. Já os menores índices foram tipicidade (0,82), precisão (0,83), relevância (0,84), variedade (0,84) e objetividade (0,88). Em relação à validade de conteúdo de cada item (CVCi), 58,3% (itens 2, 6, 7, 8, 9, 11 e 12) apresentaram um índice de concordância $\geq 0,90$, e

41,6% (itens 1, 3, 4, 5 e 10), um índice de $\geq 0,80$. Vale frisar que, apesar de índices menores, os itens ultrapassaram o CVCT (0,78) e o CVCi (0,80) mínimos (Filgueiras *et al.*, 2015; Yusoff, 2019).

Para a pré-testagem da EDCA-12, foram coletados dados de 60 acadêmicos, sendo 73,3% mulheres ($n = 44$), 23,3% homens ($n = 14$) e 3,3% não binários ($n = 2$), com idade média de 27,8 anos ($DP = 8,78$). Destes, 71,6% ($n = 43$) eram graduandos, 6,6% ($n = 4$) eram especialistas, 20% ($n = 12$) eram mestrands e 1,6% ($n = 1$), doutorando. Na Tabela 1, são apresentados os dados sociodemográficos dos participantes, fornecendo uma visão geral das características da amostra utilizada no estudo.

Tabela 1. Dados sociodemográficos dos participantes.

VARIÁVEIS	GÊNERO						TOTAL	
	Feminino		Masculino		Não binário			
Faixa etária	N	%	N	%	N	%	N	%
18–25	25	56,8	5	35,7	1	50,0	31	51,7
26–35	10	22,7	5	35,7	1	50,0	16	26,7
36–45	7	15,9	2	14,3	0	0	9	15,0
46–55	1	2,3	2	14,3	0	0	3	5,0
≥ 56	1	2,3	0	0	0	0	1	1,6
Ensino superior								
Graduando	30	68,2	11	78,6	2	100	43	71,7
Pós-graduando	3	5,3	1	7,1	0	0	4	6,7
Mestrando	10	22,7	2	14,3	0	0	12	20,0
Doutorando	1	2,3	0	0	0	0	1	1,6
Renda								
Até 1 salário	5	11,4	1	7,2	0	0	6	10,0
1–3 salários	9	20,5	3	21,4	1	50,0	13	21,7
3–5 salários	10	22,7	3	21,4	1	50,0	14	23,3
5–7 salários	8	18,1	2	14,3	0	0	10	16,7
7–9 salários	5	11,4	2	14,3	0	0	7	12,7
> 9	7	15,9	3	21,4	0	0	9	15,0
Estado								
Alagoas (AL)	6	13,6	2	14,3	0	0	8	13,3
Bahia (BA)	8	18,1	4	28,6	1	50,0	13	21,7
Minas Gerais (MG)	0	0	1	7,1	0	0	1	1,7
Rio de Janeiro (RJ)	1	2,3	0	0	0	0	1	1,7
Rio Grande do Sul (RS)	1	2,3	0	0	0	0	1	1,7
Santa Catarina (SC)	27	61,4	7	50,0	1	50,0	35	58,3
Sergipe (SE)	1	2,3	0	0	0	0	1	1,7
Depressão								
Não clínico	5	11,3	7	50,0	0	0	12	20,0
Leve	13	29,6	4	28,6	1	50,0	18	30,0
Moderada	16	36,3	3	21,4	0	0	19	31,7
Severa	10	22,7	0	0	1	50,0	11	18,3
Total	44	73,3	14	23,3	2	3,3	60	100

TRANSFERÊNCIA DO CONHECIMENTO

As variáveis selecionadas para o estudo incluíram gênero, idade, eventos parentais, eventos traumáticos, estilo cognitivo, expressão emocional, relacionamento interpessoal, autoeficácia acadêmica percebida, autorregulação da aprendizagem, senso de pertencimento e percepção sobre a universidade (Gonçalves et al., 2024). Esses aspectos foram escolhidos com base em sua relevância para a identificação de fatores de risco e proteção associados à depressão em acadêmicos.

Durante a fase de transferência do conhecimento, as observações foram rotuladas com base nos resultados do PHQ-9. As categorias de rotulagem foram definidas como “não clínico” (20%, n = 12), “depressão leve” (30%, n = 18), “depressão moderada” (31,7%, n = 19) e “depressão grave” (18,3%, n = 11).

PROCESSAMENTO DOS DADOS

Para a exploração e limpeza dos dados, estes foram organizados conforme a estrutura Tidy Data, caracterizada pela organização padronizada dos dados com o objetivo de integrar a estrutura física (forma e formato) com sua semântica (significado) (Huang & Zhao, 2020).

Nessa estrutura, cada variável contém todos os valores que medem o mesmo atributo (p. ex., gênero, idade) entre diferentes unidades, enquanto cada observação contém os valores medidos em uma mesma unidade (resposta de um participante) por meio desses atributos. Essa abordagem facilita a análise e a manipulação dos dados.

Após a organização inicial, os dados foram estruturados em uma unidade observacional (tabela). Os seguintes passos foram realizados para garantir a qualidade dos dados:

- Exploração inicial dos dados: análise descritiva para identificar distribuições, *outliers* e padrões gerais e verificação de consistência e correção de erros de digitação ou formatação.
- Descarte de amostras nulas e inválidas: remoção de entradas com dados ausentes ou inválidos para evitar viés nas análises subsequentes e verificação da completude dos dados, garantindo que todas as variáveis essenciais estejam presentes para cada observação.
- Mensuração das respostas: padronização das respostas quantitativas e qualitativas e conversão de variáveis categóricas em formatos apropriados para análise, utilizando técnicas como *One-Hot Encoding* e *Label Encoding*.
- Limpeza dos textos: remoção de pontuação, números e *stopwords* (artigos, pronomes, conjunções, etc.) para facilitar a análise textual e normalização dos textos para garantir consistência (p. ex., conversão para letras minúsculas).

Esses passos foram cruciais para preparar os dados para a análise de aprendizado de máquina, garantindo que fossem limpos, padronizados e organizados de maneira a maximizar

a eficiência e a precisão dos modelos a serem aplicados. Na Quadro 2, é possível observar a estrutura Tidy Data.

A técnica de codificação de atributos transforma os valores de determinados atributos do conjunto de dados, uma etapa importante para atender as necessidades dos algoritmos utilizados nas fases de pré-processamento (Baskoro & Sunindyo, 2019). Por exemplo, um conjunto de dados que representa o gênero de um grupo de pessoas como M (masculino) e F (feminino) precisa ser convertido em variáveis numéricas para ser utilizado por modelos preditivos que aceitam apenas entradas numéricas. Nesse caso, a representação do gênero deve ser substituída por números.

Para realizar essa transformação, foi utilizada uma combinação das técnicas *One-Hot Encoding* e *Label Encoding*. A *One-Hot Encoding* cria um atributo binário para cada valor único do atributo-alvo, variando de 0 a 1 – por exemplo, se o atributo “uso de substância” tem valores “sim” e “não”, a *One-Hot Encoding* cria duas colunas, uma para “sim” e outra para “não”, onde 1 representa a presença do atributo e 0 a ausência. Já a *Label Encoding* atribui rótulos distintos para cada valor do atributo – por exemplo, o atributo “nível de trauma” pode ser codificado como 0 para “sem traumas”, 1 para “traumas moderados” e 2 para “traumas severos”.

A decisão sobre qual técnica utilizar foi baseada em processos iterativos realizados pela equipe, considerando o número reduzido de observações e as potenciais técnicas a serem empregadas (Bernardo et al., 2020).

Para discriminar cognições, emoções, sentimentos e comportamentos, foi criado um vocabulário extraído do conjunto de dados em formato de texto (.txt), contendo adjetivos, substantivos e verbos, tanto positivos quanto negativos. Além disso, foram elaboradas listas de substâncias psicoativas, categorizadas como perturbadoras (p. ex., maconha), estimulantes (p. ex., cocaína) e depressoras (p. ex., vinho), assim como uma lista de eventos traumáticos (p. ex., hospitalização). Esse vocabulário foi complementado pelo uso das bibliotecas Pandas, Numpy e Sci-Kit para a análise de dados.

A extração das palavras para a composição do vocabulário foi realizada por meio de análise de conteúdo da base de dados e consultas a dicionários da língua portuguesa *on-line*. No total, 1.837 palavras foram tabuladas, distribuídas da seguinte forma: 23,6% (n = 433) adjetivos negativos, 31,4% (n = 577) adjetivos positivos, 20,3% (n = 372) verbos negativos, 11,8% (n = 218) verbos positivos, 2,4% (n = 45) substantivos negativos, 2,4% (n = 45) substantivos positivos, 4,1% (n = 76) eventos traumáticos e 3,8% (n = 71) substâncias psicoativas.

Para observações negativas que contêm termos positivos, foi construída uma biblioteca de palavras negativas para inverter o sentido relatado. As palavras incluem: “não”, “nada”, “jamais”, “falta”, “sem”, “nunca” e “nem”. Para essas palavras, a negação é considerada antes da expressão da ideia (p. ex., me sinto não competente, jamais serei feliz). Termos como “nenhum” e “nenhuma” foram analisados tanto antes quanto depois dos termos.

Quadro 2. Estrutura Tidy Data do projeto de inteligência artificial.

ESTUDOS DE BASE	VARIÁVEL	NOME VARIÁVEL	TIPO DE VARIÁVEL	DESCRIÇÃO	VALORES PERMITIDOS
Não há	ID do participante	ID	Númerica	Número de identificação em ordem crescente	001-999
	Gênero	GENERO	Categórica	Gênero informado pelo participante	Masculino; Feminino; Não binário
	Idade	IDADE	Númerica	Idade do paciente em anos	18-65
	Nível acadêmico	NIVEL ACAD	Categórica	Nível atual de ensino	Graduação; Pós-graduação; Mestrado; Doutorado
Weber et al. (2017) Mello et al. (2009) Sheldon et al. (2021)	Figuras parentais	FIG_PAR	Categórica	Quantas figuras parentais	001-999
	Investimento parental	INV_PAR	Categórica	Quantidade de práticas positivas ou negativas	001-999
	Traumas	TRAUMA	Categórica	Nível de eventos traumáticos	0 = sem eventos; 1 = eventos moderados; 2 = eventos severos
Cerchiarì et al. (2005) Flesch et al. (2020)	Percepção como acadêmico	CREN	Categórica	Quantidade de percepções positivas ou negativas	001-999
Zancan et al. (2021)	Atitude diante de atividades acadêmicas	AGE TRAB	Categórica	Quantidade de comportamentos relacionados à solução ou fuga/esquiva	001-999
Leão et al. (2018)	Satisfação ou insatisfação com o curso	SAT_INSAT	Categórica	Quantidade de satisfações e insatisfações	001-999
Ribeiro et al. (2020) McClelland et al. (2020) Flesch et al. (2020)	Interações sociais	INT_SOC	Númerica	Frequência de interações sociais com a rede de apoio na semana	001-007
Gotlib et al. (2010)	Qualidade das interações sociais	QUALI_SOC	Categórica	Quantidade de interações sociais positivas ou negativas	001-999
	Atividades de interesse	INT	Categórica	Mudança na execução das atividades de interesse	0 = Não; 1 = Sim
	Dias sem atividades de interesse	SEM_INT	Númerica	Dias sem execução das atividades de interesse	001-999
	Humor	HUMOR	Categórica	Quantidade de humor positivo ou negativo	001-999
Alloy et al. (2000) Mathews et al. (2005)	Visão sobre si	SELF	Categórica	Visão negativa ou positiva sobre si	0 = negativa; 1 = positiva
	Visão sobre os outros	OTHER	Categórica	Visão negativa ou positiva sobre os outros	0 = negativa; 1 = positiva
	Visão sobre o futuro	FUT	Categórica	Visão negativa ou positiva sobre o futuro	0 = negativa; 1 = positiva
	Uso de substâncias psicoativas	USO_SUBS	Categórica	Uso de substâncias psicoativas	0 = não faz uso; 1 = eventualmente; 2 = sim
Lev-Ran et al. (2014) Vieira et al. (2021) Pedrelli et al. (2016)	Tipos de substâncias psicoativas	TIP_SUBS	Categórica	Tipos de substâncias	0 = não faz uso; 1 = depressoras; 2 = perturbadoras; 3 = estimulantes
	Frequência de uso de substâncias	FREQ_SUBS	Númerica	Frequência no uso de substâncias na semana	001-007
	Frequência de atividade física	AT_FIS	Númerica	Frequência de atividade física na semana	001-007
American Psychiatric Association (IAPA, 2013)	Nível de depressão	DEPRE	Categórica	Nível de depressão	0 = sem depressão; 1 = depressão leve; 2 = depressão moderada; 3 = depressão severa

MODELAGEM DOS DADOS

Foi utilizada a abordagem de aprendizado de máquina supervisionado, definida como uma estratégia computacional em que os dados são rotulados e supervisionados para treinar modelos, permitindo prever resultados para dados não rotulados. Sustentada pela lógica indutiva, o modelo supervisionado se baseia na previsão de uma variável dependente (p. ex., depressão ou não) a partir de variáveis independentes (p. ex., tipo de humor, nível de atividade física, etc.) (Presotto, 2021).

Os testes foram realizados utilizando os seguintes algoritmos: LR, LDA, KNN, CART, NB e SVM, os quais foram implementados na linguagem Python, utilizando bibliotecas típicas para análises de dados.

A validação cruzada foi empregada para avaliar a capacidade de generalização dos modelos, utilizando o método *Hold-out*. Nesse método, 80% dos dados ($n = 48$) foram utilizados para treinamento, enquanto 20% ($n = 12$) foram reservados para teste e validação. Esse processo foi repetido múltiplas vezes, alternando os conjuntos de dados de treinamento e teste para estimar a precisão dos modelos. Esse tipo de validação reduz significativamente o viés, pois a maior parte dos dados é usada para treinamento, e a variância, já que uma parte substancial deles também é usada para validação (Garnier *et al.*, 2022).

Os resultados obtidos demonstraram que o algoritmo LR atingiu uma precisão de 97%, seguido pela CART com 82%, NB com 81%, LDA com 65%, KNN com 48% e SVM com 45%.

ENTREGA

Para facilitar o uso do algoritmo, foi desenvolvida uma interface gráfica na qual os itens são apresentados um por vez em uma tela. Abaixo de cada item, há uma caixa de respostas para que o usuário possa inserir suas respostas. Após a inserção, o usuário avança pelas perguntas até alcançar a tela “Obter Resultado”, conforme ilustrado na Figura 2. Um vídeo com a execução pode ser acessado no Yoututbe. (Gonçalves, dez. 2023)

Embora não tenham sido realizados estudos focados na experiência do usuário devido à limitação de tempo para o desenvolvimento do projeto, futuras pesquisas devem incluir a validação com o público-alvo e testagem comparativa com instrumentos padrão-ouro. Essas etapas são essenciais para o desenvolvimento de instrumentos psicológicos, sejam eles digitais, analógicos ou impressos (Pressman *et al.*, 2021). Essa abordagem assegura que os instrumentos desenvolvidos atendam aos requisitos de validade e confiabilidade necessários para a prática clínica e a pesquisa em psicologia.

QUESTÕES ÉTICAS E APLICAÇÃO DE INTELIGÊNCIA ARTIFICIAL EM SAÚDE MENTAL

O desenvolvimento e o uso de tecnologias de IA em contextos de saúde mental trazem desafios éticos que devem

ser ponderados. Primeiramente, há a questão da privacidade e da confidencialidade dos dados. Ferramentas de IA dependem de grandes volumes de dados sensíveis, como registros de saúde e informações psicossociais, que, se mal gerenciados, podem comprometer a privacidade dos indivíduos (Martínez-Pérez *et al.*, 2013). Além disso, a transparência no uso dos algoritmos é importante: é necessário que os critérios de decisão e os processos de aprendizado de máquina sejam compreensíveis para profissionais e pacientes, evitando viés algorítmico que possa discriminar ou estigmatizar determinados grupos (Anthes, 2016).

Outro ponto relevante é o papel do profissional de saúde mental. A IA deve ser uma ferramenta de apoio, e não substituir o julgamento clínico. O uso excessivo de tecnologias pode, em algumas circunstâncias, reduzir a relação terapêutica ou criar dependência excessiva dos sistemas, em detrimento da autonomia profissional e do paciente (Shatte *et al.*, 2019).

Apesar dessas considerações, a proposta apresentada tem implicações práticas significativas no contexto universitário, que podem ser exploradas em estudos futuros. A integração dessa tecnologia pode ocorrer de diversas formas:

1. Programas preventivos e educacionais: a aplicação pode ser utilizada como uma ferramenta de rastreamento de risco, auxiliando universidades a implementarem políticas de prevenção primária e intervenções rápidas em grupos vulneráveis. Informes gerados pela IA podem guiar ações educativas sobre saúde mental.
2. Apoio aos serviços de saúde universitários: centros de atendimento psicológico universitário podem usar a ferramenta para triagem inicial, permitindo identificar casos de risco elevado e direcionar recursos humanos de forma mais eficiente. Isso contribui para reduzir sobrecargas nos serviços.
3. Integração com plataformas acadêmicas: a IA pode ser incorporada em sistemas já existentes de gestão acadêmica, como ambientes virtuais de aprendizagem (AVA) ou portais do aluno. Dessa forma, avaliações periódicas e relatórios podem ser gerados, facilitando a monitorização longitudinal da saúde mental dos estudantes.
4. Capacitação de profissionais e orientadores: a tecnologia pode ser aliada na capacitação de professores e orientadores, oferecendo *insights* baseados em dados sobre o impacto de fatores acadêmicos e sociais na saúde mental dos alunos.

Essa integração, no entanto, demanda investimentos em treinamento de profissionais para a adequada interpretação dos resultados gerados pela IA, garantindo que a aplicação prática esteja alinhada às diretrizes éticas e científicas.

Entrevista para Depressão Centrada em Acadêmicos

Pergunta :
Às vezes acontecem coisas extremamente perturbadoras às pessoas (p. ex. de ameaça à vida, um desastre, um acidente muito grave, ser agredido fisicamente ou sexualmente, ver alguém ferido ou hospitalizado, etc.). Caso algo dessa natureza tenha acontecido com você, em algum momento durante a sua vida, me relate brevemente:

Resposta:

Próxima

Entrevista para Depressão Centrada em Acadêmicos

Pergunta :
Ainda sobre suas relações sociais, como você descreveria seu convívio com os pares (amigos, colegas de quarto, colegas de faculdade, etc.):

Resposta:

Próxima

Entrevista para Depressão Centrada em Acadêmicos

Pergunta :
Se você pudesse resumir em uma palavra como você se vê como pessoa, que palavra seria essa?

Resposta:

Obter Resultado

Figura 2. Telas de respostas da EDCA-12 informatizada.

CONSIDERAÇÕES FINAIS

Os objetivos do presente estudo foram alcançados ao descrever o desenvolvimento de uma tecnologia baseada em IA para identificação de depressão em acadêmicos, integrando dimensões contextuais e vivenciais desse público. A entrevista adaptada demonstrou validade de conteúdo robusta (CVC = 0,89) e alta consistência interna ($\alpha = 0,95$), atestada por juízes

especialistas e a população-alvo. Além disso, os modelos de aprendizado de máquina apresentaram desempenho promissor, com destaque para o modelo LR, que atingiu 97% de precisão.

Aplicações de IA na área da saúde aumentam progressivamente, o que denota a necessidade de os profissionais se familiarizarem com essa modalidade de tecnologia. Apesar da modesta inserção da IA na saúde mental, o seu crescimento é visível, o que é possibilitado

pelas características da própria tecnologia, já que seu desenvolvimento acelerado se relaciona ao uso contínuo de algoritmos cada vez mais eficazes. Isso gera um ciclo de soluções cada vez mais refinado, que aumenta a disposição de uso social (Institute Massachusetts Technology [MIT], 2020).

Esse crescimento culmina na necessidade de pesquisas sobre os temas, pois as tendências futuras indicam que aplicações de IA na saúde mental se tornarão cada vez mais comuns. Alguns estudos e comentários recentes, como os de Aktan et al. (2022), já revelam a preferência por uma psicoterapia baseada em IA, pela possibilidade de abordar assuntos embaraçosos confortavelmente, acessar a psicoterapia em qualquer momento e lugar e reduzir estigmas. Em contrapartida, o fenômeno do uso excessivo de tecnologias necessita de exploração, já que estudos sobre intervenções tecnológicas em saúde sem a devida base empírica tendem a reforçar problemas para os quais as intervenções são projetadas para solucionar.

Especificamente no campo da psicometria, os benefícios do uso de algoritmos baseados em IA são notáveis. Modelos baseados em IA demonstram potencial para identificar os itens mais relevantes em escalas psicométricas, aumentando a precisão na avaliação de fenômenos psicológicos e mitigando riscos de baixa confiabilidade ou distorções (Gonzalez, 2020; Lötsch et al., 2018).

Entre as limitações do estudo, é importante reconhecer que a amostra de universitários utilizada foi relativamente pequena, o que limita a generalização dos achados. Embora a proposta deste artigo tenha sido apresentar o desenvolvimento da tecnologia baseada em IA, estudos futuros devem ampliar a amostra, incorporando participantes de diferentes contextos, cursos e instituições, de modo a garantir maior representatividade e robustez aos resultados. Além disso, a inclusão de amostras mais diversas permitirá a comparação entre subgrupos e a validação da tecnologia em cenários variados, fortalecendo suas aplicabilidades clínica e acadêmica.

Além disso, a coleta de dados em um período específico não permite captar variações sazonais ou eventos que impactem a saúde mental dos participantes. O uso de instrumentos de autorrelato também representa uma limitação, devido ao potencial de vieses de resposta e autoavaliação. Assim, a tecnologia desenvolvida ainda requer validação empírica mais ampla e comparações com instrumentos padrão-ouro para confirmar sua eficácia em diferentes contextos.

Para estudos futuros, sugere-se aprimorar a interface gráfica do *software* em formato de aplicativo ou sistema *web*, com base em princípios de *UX Design* (experiência do usuário), para tornar o uso mais acessível e atrativo. Além disso, é necessário expandir a coleta de dados para melhorar o desempenho dos modelos e conduzir testes empíricos que verifiquem a efetividade das funcionalidades. Melhorias na usabilidade da plataforma também podem ser implementadas para facilitar sua aplicação em contextos clínicos e acadêmicos.

REFERÊNCIAS

- Ada.com (c2025). <https://ada.com/pt/>
- Aktan, M. E., Turhan, Z., & Dolu, I. (2022). Attitudes and perspectives towards the preferences for artificial intelligence in psychotherapy. *Computers in Human Behavior*, 133.
- Almeida, L., Soares, A. P. C., & Ferreira, J. A. G. (2001). Adaptação, rendimento e desenvolvimento dos estudantes do ensino superior: Construção/validação do questionário de vivências acadêmicas. *Methodus Revista Científica e Cultural*, 3(5), 3-20.
- Alloy, L. B., Abramson, L. Y., Hogan, M. E., Whitehouse, W. G., Rose, D. T., Robinson, M. S., & Lapkin, J. B. (2000). The Temple-Wisconsin Cognitive Vulnerability to Depression Project: Lifetime history of Axis I psychopathology in individuals at high and low cognitive risk for depression. *Journal of Abnormal Psychology*, 109(3), 403-418.
- Anthes, E. (2016). Mental health: There's an app for that. *Nature*, 532, 20-23.
- Baskoro, S., & Sunindyo, W. (2019). Predicting issue handling process using case attributes and categorical variable encoding techniques. *2019 International Conference on Data and Software Engineering (ICoDSE)*. <https://doi.org/10.1109/ICoDSE48700.2019.9092617>
- Bernardo, F., Ferro, M., Vieira, V., Silva, G., & Schulze, B. (2020). Em busca de uma Inteligência Artificial ecologicamente viável: Um estudo de caso do consumo energético de algoritmos de Árvore de Decisão. *Anais do XXI Simpósio em Sistemas Computacionais de Alto Desempenho*. <https://sol.sbc.org.br/index.php/sscad/article/view/14068/13916>
- Cass.ai (c2025). <https://www.cass.ai/x2ai-home>
- Cerchiari, E. A. N., Caetano, D., & Faccenda, O. (2005). Prevalência de transtornos mentais menores em estudantes universitários. *Estudos de Psicologia*, 10(3).
- Cunha, C. M., Nepomuceno, E., Manzato, R. O., Cunha, D. C. P. T., Silva, D., & Dantas, R. A. S. (2018). Cultural adaptation and validation of the Brazilian version of the Patient Activation Measure-22 items. *Revista Brasileira de Enfermagem*, 71(4), 1891-1898.
- Dwivedi, Y., Hughes, L., Ismagilova, E., Aarts, G., Coombs, C., Crick, T., ... Williams, M. (2019). Artificial Intelligence (AI): Multidisciplinary perspectives on emerging challenges, opportunities, and agenda for research, practice and policy. *International Journal of Information Management*, 57(7).
- Filgueiras, A., Galvão, B. O., Pires, P., Fioravanti-Bastos, A. C., Hora, G. P. R., Santana, C. M. T., & Landeira-Fernandez, J. (2015). Tradução e adaptação semântica do Questionário de Controle Atencional para o contexto brasileiro. *Estudos de Psicologia*, 32(2), 173-185.
- Flesch, B. D., Houvèssou, G. M., Munhoz, T. N., & Fassa, A. G. (2020). Major depressive episode among university students in Southern Brazil. *Revista de Saúde Pública*, 54, 1-11.
- Fórum Nacional de Pró-Reitores de Assuntos Comunitários e Estudantis (FONAPRACE). (2016). *IV Pesquisa do perfil socioeconômico e cultural dos estudantes de graduação das instituições federais de ensino superior brasileiras: 2014*. FONAPRACE. https://www.andifes.org.br/wp-content/uploads/2017/11/Pesquisa-de-Perfil-dos-Graduandos-das-IFES_2014.pdf

- Fulmer, R., Joerin, A., Gentile, B., Lakerink, L., & Rauws, M. (2018). Using Psychological Artificial Intelligence (Tess) to relieve symptoms of depression and anxiety: Randomized controlled trial. *JMIR Mental Health*, 5(4), e64.
- Garnier, R., Langhendries, R., & Rynkiewicz, J. (2022). Hold-out estimates of prediction models for Markov processes. *Statistics*, 57(2), 458-481.
- Gonçalves, J. (2023). Proposta de formulação de caso nomotética em terapia cognitivo comportamental. *Revista Científica Sophia*, 15(2).
- Gonçalves, J. (dez. 2023). Protótipo IA para depressão em acadêmicos. <https://www.youtube.com/watch?v=eTbtv8ujt1M>
- Gonçalves, J., & Alves, A. G. (2024). O uso de Inteligência Artificial no tratamento do transtorno depressivo maior: Revisão sistemática. *Revista Psicologia em Foco*.
- Gonzalez, O. (2020). Psychometric and machine learning approaches to reduce the length of scales. *Multivariate Behavioral Research*, 56(6), 903-919.
- Gorenstein, C., & Wang, Y. (Orgs.). (2024). *Instrumentos de avaliação em saúde mental* (2. ed.). Artmed.
- Gotlib, I. H., & Joormann, J. (2010). Cognition and depression: Current status and future directions. *Annual Review of Clinical Psychology*, 6, 285-312.
- Graham, S., Depp, C., Lee, E. E., Nebeker, C., Tu, X., Kim, H., & Jeste, D. V. (2019). Artificial Intelligence for mental health and mental illnesses: An overview. *Current Psychiatry Reports*, 21(11), 116.
- Huang, T., & Zhao, B. (2020). Tidyfist: Tidy verbs for fast data manipulation. *The Journal of Open Source Software*, 5(52), 2388.
- Institute Massachusetts Technology (MIT). (2020). *Inteligência Artificial nas grandes organizações latino-americanas: Visão geral da adoção e tendências na região*. Technology Review.
- Jungmann, S. M., Klan, T., Kuhn, S., & Jungmann, F. (2019). Accuracy of a Chatbot (ADA) in the diagnosis of mental disorders: Comparative case study with lay and expert users. *JMIR Formative Research*, 3(4), e13863.
- Kusters, R., Misevic, D., Berry, H., Cully, A., Cunff, Y., Dandoy, L., ... Wehbi, F. (2020). Interdisciplinary research in Artificial Intelligence: Challenges and opportunities. *Frontiers in Big Data*, 3, 577974.
- Leão, A. M., Gomes, I. P., Ferreira, M. J. M., & Cavalcanti, L. P. G. (2018). Prevalência e fatores associados à depressão e ansiedade entre estudantes universitários da área da saúde de um grande centro urbano do Nordeste do Brasil. *Revista Brasileira de Educação Médica*, 42(4), 55-65.
- Lev-Ran, S., Roerecke, M., Le Foll, B., George, T. P., McKenzie, K., & Rehm, J. (2014). The association between cannabis use and depression: A systematic review and meta-analysis of longitudinal studies. *Psychological Medicine*, 44(4), 797-810.
- Lötsch, J., Sipilä, R., Dimova, V., & Kalso, E. (2018). Machine-learned selection of psychological questionnaire items relevant to the development of persistent pain after breast cancer surgery. *British Journal of Anaesthesia*, 121(5), 1123-1132.
- Lottemberg, C., Silva, P. E., & Klajner, S. (2019). *A revolução digital na saúde: Como a inteligência artificial e a internet das coisas tornam o cuidado mais humano, eficiente e sustentável*. Editora dos Editores.
- Lynn, M. R. (1986). Determination and quantification of content validity. *Nursing Research*, 35(6), 382-385.
- Mathews, A., & MacLeod, C. (2005). Cognitive vulnerability to emotional disorders. *Annual Review of Clinical Psychology*, 1, 167-195.
- Martínez-Pérez, B., De La Torre-Díez, I., & López-Coronado, M. (2013). Mobile health applications for the most prevalent conditions by the World Health Organization: Review and analysis. *Journal of Medical Internet Research*, 15(6), e120.
- Mello, M., Faria, A. A., Mello, A. F., Carpenter, L., Tyrka, A. R., & Price, L. (2009). Maus-tratos na infância e psicopatologia no adulto: Caminhos para a disfunção do eixo hipotálamo-pituitária-adrenal. *Revista Brasileira de Psiquiatria*, 31(2), 41-48.
- McClelland, H., Evans, J. J., Nowland, R., Ferguson, E., & O'Connor, R. C. (2020). Loneliness as a predictor of suicidal ideation and behaviour: A systematic review and meta-analysis of prospective studies. *Journal of Affective Disorders*, 274, 880-896.
- Moura, J. R. A., Silva, C. B., Rocha, A. E. S. H. R. S. D., Amorim, T. R. S. A., & Silva, A. R. V. S. (2019). Construção e validação de cartilha para prevenção do excesso ponderal em adolescentes. *Revista Acta Paulista de Enfermagem*, 32(4), 365-373.
- Nemesure, M. D., Heinz, M. V., Huang, R., & Jacobson, N. C. (2021). Predictive modeling of depression and anxiety using electronic health records and a novel machine learning approach with artificial intelligence. *Scientific Report*, 11(1), 1980.
- Paetzold, M. G., Silva, L. de L., & Simões, M. R. (2021). Métodos de rastreamento da ansiedade e depressão em estudantes universitários: Revisão integrativa. *Saúde Coletiva*, 11(60), 4686-4695.
- Pasquali, L. (2024). Princípios da elaboração de escalas. In C. Gorenstein, & Y. Wang (Orgs.), *Instrumentos de avaliação em saúde mental* (pp. 6-13). Artmed.
- Pedrelli, P., Borsari, B., Lipson, S. K., Heinze, J., & Eisenberg, D. (2016). Diferenças de gênero nas relações entre transtorno depressivo maior, uso pesado de álcool e envolvimento com tratamento de saúde mental entre estudantes universitários. *Journal of Studies on Alcohol and Drugs*, 77(4), 620-628.
- Polydoro, S. A. J., Primi, R., Serpa, M. N. F., Zaroni, M. M. H., & Pombal, K. C. P. (2001). Desenvolvimento de uma escala de integração ao ensino superior. *PsicoUSF*, 6(1), 11-17.
- Presotto, J. G. C. (2021). *Métodos de aprendizado de máquina fracamente supervisionados baseados em ranqueamento* [Dissertação de mestrado]. Universidade Estadual Paulista. <https://repositorio.unesp.br/items/12a0fa2c-9702-49f0-86ba-756e3bc8557e>
- Pressman, R. S., & Maxim, B. R. (2021). *Engenharia de software: Uma abordagem profissional* (9. ed.). AMGH.
- Renn, B. N., Schurr, M. S., Zaslavsky, O., & Pratap, A. (2021). Artificial Intelligence: An interprofessional perspective on implications for geriatric mental health research and care. *Frontiers in Psychiatry*, 12, 734909.

- Ribeiro, C. F., Lemos, C. M. C., Alt, N. N., Marins, R. L. T., Corbiceiro, W. C. H., & Nascimento, M. I. (2020). Prevalence of and factors associated with depression and anxiety in Brazilian medical students. *Revista Brasileira de Educação Médica*, 44(1).
- Sampieri, R. H., Collado, C. F., & Lucio, M. P. B. (2013). *Metodologia da pesquisa* (5. ed.). AMGH.
- Santos, I. S. (2013). Sensibilidade e especificidade do Patient Health Questionnaire-9 (PHQ-9) entre adultos da população geral. *Cadernos de Saúde Pública*, 29(8), 1533-1543.
- Shatte, A. B. R., Hutchinson, D. M., & Teague, S. J. (2019). Machine learning in mental health: A scoping review of methods and applications. *Psychological Medicine*, 49(9), 1426-1448.
- Sheldon, E., Simmonds-Buckley, M., Bone, C., Mascarenhas, T., Chan, N., Wincott, M., ... Sow, K. (2021). Prevalence and risk factors for mental health problems in university undergraduate students: A systematic review with meta-analysis. *Journal of Affective Disorders*, 287, 282-292.
- Sijia, Z., Jingping, Z., & Lulu, Z. (2022). Application of Artificial Intelligence on psychological interventions and diagnosis: An overview. *Frontiers in Psychiatry*, 13, 811665.
- Tao, X., Chi, O., Delaney, P. J., Li, L., & Huang, J. (2021). Detecting depression using an ensemble classifier based on Quality of Life scales. *Brain Informatics*, 8(1), 2.
- Vieira, F. S. T., Muraro, A. P., Muraro, P. R. M. R., Rosely, S., Pereira, R. A., & Ferreira, M. G. (2021). Lifestyle-related behaviors and depressive symptoms in college students. *Cadernos de Saúde Pública*, 37(10).
- Weber, D., & Natalia, L. (2017). Relações entre práticas educativas parentais percebidas e a autoestima, sinais de depressão e uso de substâncias por adolescentes. *International Journal of Developmental and Educational Psychology*, 2(1), 157-167.
- Yusoff, M. S. B. (2019). ABC of content validation and content validity index calculation. *Resource*, 11(2), 49-54.
- Zancan, R. K., Machado, A. B. C., Boff, N., & Oliveira, M. S. (2021). Estresse, ansiedade, depressão e inflexibilidade psicológica em estudantes universitários de graduação e pós-graduação. *Estudos e Pesquisas em Psicologia*, 21(2), 749-767.

Artigo submetido em: 4 de julho de 2024.

Artigo Aceito em: 18 de dezembro de 2024.

Artigo publicado online em: dia de mês de ano.

Fonte de financiamento: Fundo Estadual de Apoio à Manutenção e ao Desenvolvimento da Educação Superior (FUMDES).

Editora responsável:
Carmem Beatriz Neufeld

Outras informações relevantes:
Este artigo foi submetido no GNPapers da RBTC código 509.

Trabalho vencedor na categoria Dissertação de Mestrado do Prêmio Monográfico Bernard Rangé do ano de 2024.