



ARTIGO

DESAFIOS E OPORTUNIDADES NA INTEGRAÇÃO DO AMBIENTE CLÍNICO E DIGITAL PARA APOIO AO DIAGNÓSTICO DA GAGUEIRA

POR

*Rodrigo José Silva de Almeida, Damires Yluska Souza Fernandes,
Luciana Pereira Oliveira e Débora Vasconcelos Correia*
rodrigo-almeida.ra@academico.ifpb.edu.br, damires@ifpb.edu.br,
luciana.oliveira@ifpb.edu.br, debora@ccs.ufpb.br

A gagueira é um transtorno da fluência que inicia na infância e pertence ao grupo dos transtornos da comunicação e do neurodesenvolvimento [1]. Ela acomete cerca de 5% das crianças em idade pré-escolar e 1% da população adulta, e o seu surgimento ocorre mais frequentemente entre os 2 e os 4 anos de idade, de forma gradual ou abrupta [2]. Pessoas que gaguejam apre-

sentam padrões neurais atípicos estruturalmente e funcionalmente [3]. Dentre os principais sinais e sintomas do transtorno, encontra-se a produção da fala com excessivas disfluências típicas da gagueira como repetições de sons, sílabas e palavras monossilábicas, bloqueios, prolongamentos, pausas, entre outras.

Apesar da literatura apontar achados em neuroimagens e padrões atípicos da

atividade elétrica cortical em quem gagueja, atualmente, essas técnicas se restringem à pesquisa e não estão disponíveis para a clínica. O diagnóstico do transtorno é realizado pelo fonoaudiólogo, preferencialmente especialista em Fluência, que analisa os dados históricos da queixa e da fluência na fala. A história da queixa é comumente registrada em papel durante a anamnese com o paciente e armazenada em prontuários físicos. A análise do histórico viabiliza o diagnóstico da gagueira e demais transtornos da fluência, também identificando risco para a presença de comorbidades, como transtornos do sono, ansiedade social, entre outros.

No Brasil, para fins clínicos e de pesquisa, o instrumento validado para a avaliação da fluência na fala é o Protocolo de Avaliação da Fluência, que faz parte do Teste de Linguagem Infantil nas áreas de fonologia, vocabulário, fluência e pragmática – ABFW [4]. O procedimento de avaliação requer a transcrição manual da coleta de amostra de fala do indivíduo avaliado, usualmente com uma ferramenta de edição de texto. Também, de forma manual, o fonoaudiólogo identifica e quantifica as disfluências, registra o tempo total da amostra de fala, a quantidade de sílabas e palavras produzidas por minuto, realiza os cálculos necessários para a obtenção dessas medidas e registra observações complementares durante a fala (piscar de olhos, estalar de língua, etc.). A observação de 3% de disfluências, em uma amostra contendo 200 sílabas fluentes, pode ser conside-

rado um indicador de gagueira [5].

No cenário internacional, o instrumento mais utilizado para avaliação da fluência na fala é o SSI-4 (*Stuttering Severity Instrument*), atualmente na sua quarta edição. O SSI analisa a frequência e duração das disfluências, concomitantes físicos e naturalidade da fala [6]. Nas duas últimas edições do SSI, esta análise passou a ser facilitada pelo *Computerizing the Scoring of Stuttering Severity* (CSSS-2), software desenvolvido para contagem de sílabas (fluentes e gaguejadas), cálculo da porcentagem de sílabas gaguejadas, determinação da duração média dos três eventos mais longos de gagueira, e medição da velocidade de fala com base no número de sílabas por minuto [7]. Para utilizar o *software*, é necessário reproduzir a amostra de fala em um reprodutor de mídia, e a medição automática é feita a partir da análise dos pressionamentos de tecla e cliques no mouse realizados pelo avaliador, para registro do intervalo de tempo e contagem de sílabas fluentes e gaguejadas [7].

Cabe pontuar que, em ambos os instrumentos de avaliação, a acurácia e confiabilidade da análise dos dados dependem diretamente do examinador e da sua experiência. Além disso, tanto o Protocolo de Avaliação da Fluência do ABFW, em português, quanto o SSI-4, em inglês, são produtos comerciais e utilizam diferentes formas para registrar as disfluências e identificar a gagueira. No âmbito da pesquisa, o fato dos principais instrumentos de avaliação e softwares disponíveis para o diagnóstico da gagueira serem produtos comerciais

inviabiliza as práticas da *Open Science* e o alinhamento aos padrões FAIR (*Findability, Accessibility, Interoperability e Reusability*) [8]. Ou seja, é um desafio ter tais softwares open source [8].

Neste contexto, percebe-se a importância de se buscar a integração do ambiente clínico com o mundo digital, através de tecnologias da informação e comunicação (TICs). Atividades manuais e problemas complexos em diversas áreas, inclusive na Saúde, têm fomentado a necessidade de softwares para não somente apoiar automatização de tarefas, mas também a indução de hipóteses a partir de experiências anteriores. Este cenário de solução computacional envolve o uso de inteligência artificial, em especial, de técnicas de Aprendizado de Máquina (AM) e/ou de Aprendizado Profundo (AP) [9].

O AM permite ao programa aprender um determinado comportamento ou padrão, a partir de exemplos [10], sendo a base técnica para a Ciência de Dados, termo comum atualmente usado no contexto de descoberta do conhecimento [11]. O AP, por sua vez, é um subcampo do AM que usa conceitos de redes neurais artificiais [12] e tem sido comumente aplicado em Visão Computacional, Análise de Sentimentos e em outras áreas. Algoritmos de AM aprendem a induzir uma função ou hipótese, capaz de resolver um problema, a partir de dados que representam observações associadas àquele problema. No domínio da Saúde, registros eletrônicos podem ser entradas para o AM que tem como saída modelos treinados para o apoio em decisões de diagnósticos e políticas preventivas por parte dos profissionais de saúde.

Com respeito à gagueira, a fim de cooperar com pesquisas sobre a identificação deste transtorno, repositórios de acesso aberto e conjuntos de dados de falas gaguejadas têm sido construídos em inglês e alemão [13], permitindo, a partir destes, o uso de AM.

A utilização de novas tecnologias para resolução de problemas em saúde vem crescendo em todo mundo. Como ilustração, o primeiro uso de redes neurais para identificação da gagueira foi publicado em 1995 [14] e, recentemente, uma revisão sistemática sobre abordagens de AM para detectar a gagueira avaliou modelos para o reconhecimento automático da fala [13]. O estudo propõe que as técnicas de AP podem melhorar a classificação automática da gagueira e que mais trabalhos são necessários para confirmar essa proposição. Outra revisão sobre AM e gagueira [15] apresentou que o transtorno possui uma característica não linear ao longo das suas diferentes tipologias. Além disso, as abordagens exigem a atuação humana na seleção de atributos antes de submeter os dados aos classificadores. Neste contexto, o estudo propõe que, para identificar a gagueira utilizando modelos de AP, os dados devem ser devidamente rotulados e abrangentes, para alcançar uma variabilidade de amostra, contendo gênero, idioma e dialeto. Logo, o aumento do tamanho dos dados e sua qualidade são desafios a serem estudados para melhorar os modelos na identificação da gagueira [15].

Nesta perspectiva, o atual processo de diagnóstico da gagueira apresenta desafios a serem vencidos com apoio do mundo digital. São eles: registros manuais e arma-

zenamento de dados, falta de padronização para identificação das disfluências, possibilidade de “erro humano”, instrumentos proprietários para a avaliação da fluência, ausência de um repositório de acesso aberto a dados de falas gaguejadas em português brasileiro e abordagens em AM que necessitam serem aprimoradas e aplicadas a contextos reais de apoio ao diagnóstico.

Esses desafios podem ser visualizados como oportunidades de integração entre o ambiente clínico e o digital para o apoio

ao diagnóstico da gagueira. Em outros termos, são significativas as oportunidades a serem exploradas nessa integração clínica-digital, o que pode trazer benefícios tanto no âmbito nacional quanto internacional à problemática discutida. Nesse panorama, o fonoaudiólogo pode obter benefícios do trabalho de pesquisadores em Ciência de Dados com AM e softwares para diagnóstico da gagueira.

Referências:

1. AMERICAN PSYCHIATRIC ASSOCIATION. Childhood-Onset Fluency Disorder (Stuttering). In: Diagnostic and statistical manual of mental disorders. 5th ed. Washington, DC: American Psychiatric Association, 2022.
2. YAIRI, E.; AMBROSE, N. Epidemiology of stuttering: 21st century advances. *Journal of Fluency Disorders*, v. 38, n. 2, p. 66-87, 2013.
3. ETCHELL, A. C. et al. A systematic literature review of neuroimaging research on developmental stuttering between 1995 and 2016. *Journal of Fluency Disorders*, v. 55, p. 6-45, 2018.
4. ANDRADE, C. R. F. Fluência. In: ANDRADE, C. R. F.; BEFI-LOPES, D. M.; FERNANDES, F. D. M.; WERTZNER, H. F. (Eds.). ABFW - Teste de Linguagem Infantil: nas áreas de Fonologia, Vocabulário, Fluência e Pragmática. São Paulo: Pró-Fono, 2023.
5. JANSSEN-VERKASALO, E. et al. Speech disfluencies in typically developing Finnish-speaking children – preliminary results. *Clinical Linguistics & Phonetics*, 2021.
6. RILEY, G. The Stuttering Severity Instrument for Adults and Children (SSI-4) (4th ed.). Austin, TX: PRO-ED, 2009.
7. REZAI, H. et al. Duration of stuttered syllables measured by “Computerized Scoring of the Stuttering Severity (CSSS)” and “Pratt”. *Iranian Rehabilitation Journal*, 2017.
8. MACWHINNEY, B.; BERNSTEIN RATNER, N. Dynamic norming and open science. *Journal of Speech, Language, and Hearing Research*, v. 65, n. 3, p. 1183-1185, 2022.
9. OLIVEIRA, L. P. et al. Deep Learning Library Performance Analysis on Raspberry (IoT Device). 2021. doi: https://doi.org/10.1007/978-3-030-75100-5_33.
10. MITCHELL, T. *Machine Learning*. New York, NY: McGraw-Hill, 1997.
11. MARTÍNEZ-PLUMED, F. et al. CRISP-DM Twenty Years Later: From Data Mining Processes to Data Science Trajectories. *IEEE Transactions on Knowledge and Data Engineering*, v. 33, n. 8, p. 3048-3061, 01 de agosto de 2021. Doi: 10.1109/TKDE.2019.2962680.
12. LECUN, Y. et al. Deep learning. *Nature*, v. 521, p. 436-444, 2015. Disponível em: <https://doi.org/10.1038/nature14539>.
13. BARRETT, L.; HU, J.; HOWELL, P. Systematic Review of Machine Learning Approaches for Detecting Developmental Stuttering. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 2022. doi: 10.1109/TASLP.2022.3155295.
14. HOWELL, P.; SACKIN, S. Automatic recognition of repetitions and prolongations in stuttered speech. In: *Proceedings of the first World Congress on fluency disorders*. Nijmegen, The Netherlands: University Press Nijmegen, 1995.
15. SHEIKH, S. A. et al. Machine learning for stuttering identification: Review, challenges and future directions. *Neurocomputing*, 2022. doi: <https://doi.org/10.1016/j.neucom.2022.10.015>.



RODRIGO ALMEIDA é engenheiro eletricitista, especialista em Ciência de Dados e Big Data e mestrando em Tecnologia da Informação pelo IFPB. Suas pesquisas têm focado na gestão e desenvolvimento de sistemas aplicados à saúde.



DAMIRES SOUZA é professora e pesquisadora no PPGTI/IFPB, mestre e doutora em Ciência da Computação pela UFPE. Atua em pesquisas no contexto de gerenciamento de dados, Ciência dos Dados, Aprendizado de Máquina e Análise de Sentimentos.



LUCIANA OLIVEIRA é professora e pesquisadora no PPGTI/IFPB, mestre e doutora em Ciência da Computação pela UFPE. Suas pesquisas têm se focado em automação, sustentabilidade, IoT e Inteligência Artificial.



DÉBORA CORREIA é fonoaudióloga especialista em Fluência e Neurociência Aplicada, professora e pesquisadora na UFPB, mestre e doutora em Linguística pela UFPB. Suas pesquisas têm focado o processamento linguístico de pessoas que gaguejam, avaliação e diagnóstico em Fluência.