

ANÁLISES QUANTITATIVAS DE DADOS QUALITATIVOS: USO DE TÉCNICAS DE MINERAÇÃO DE TEXTOS PARA A CLÍNICA MUSICOTERAPÊUTICA

Jeniffer Soares dos Reis¹

Frederico Gonçalves Pedrosa²

Resumo: A mineração de textos é um processo de mineração de dados que tem como objetivo extrair informações úteis de conjuntos de dados não estruturados ou semiestruturados, como e-mails, arquivos HTML ou transcrições. Este estudo propõe a utilização de técnicas de mineração de textos para avaliar a comunicação verbal em sessões de musicoterapia. Para tanto, foram transcritas sessões realizadas pelo projeto Efeitos de Intervenções Musicoterapêuticas na Qualidade de Vida de mulheres negras. As técnicas de nuvem de palavras, modelagem por tópicos e análise de sentimentos foram empregadas nesta pesquisa. A modelagem por tópicos identificou quatro agrupamentos de palavras denominados de “Mulheres Negras”, “Reflexões”, “Musicoterapia” e “Dores”. Por sua vez, a análise de sentimentos identificou uma distribuição ampla de sentimentos, com predominância de sentenças neutras ou positivas, fortemente enviesada para a direita e concentrada em torno da média, com poucas sentenças extremamente negativas ou positivas. Estes dados sugerem que as sessões trataram de questões sentimentais relacionadas às mulheres negras participantes e promoveram bem-estar para esta população. De acordo com os relatos das participantes em resposta a um questionário ao fim dos atendimentos musicoterapêuticos, os resultados da mineração de textos estão em consonância com a percepção das participantes. Neste sentido, a mineração de textos é uma técnica promissora para a compreensão da comunicação verbal em atendimentos musicoterapêuticos, e pode ser utilizada em futuras pesquisas para investigar, com mais evidências, estas e outras possibilidades para a prática clínica da musicoterapêutica.

Palavras-chave: Musicoterapia. Mulheres negras. Mineração de Textos. Saúde Mental.

¹ Musicista e bacharel em Musicoterapia voltada para área social e de saúde mental. Possui experiência em atendimentos clínicos à crianças com TEA, instituições voltadas ao atendimento e inclusão social de sujeitos com sofrimento mental (Cersam's/ SRT's), instituição de longa permanência para idosos (ILPI) e projetos filantrópicos.

² Docente da Graduação em Música com Habilitação em Musicoterapia da Universidade Federal de Minas Gerais. Doutor em Música pela Universidade Federal de Minas Gerais (2023), Mestre em Musica pela Universidade Federal do Paraná (2018). Participa do grupo de pesquisa Centro de Estudos em Musicoterapia, CEMT-CNPq.

QUANTITATIVE ANALYSIS OF QUALITATIVE DATA: USE OF TEXT MINING TECHNIQUES FOR THE MUSIC THERAPY CLINIC

Summary: Text mining is a data mining process that aims to extract useful information from unstructured or semi-structured data sets, such as emails, HTML files or transcripts. This study proposes the use of text mining techniques to assess verbal communication in music therapy sessions. For this purpose, sessions carried out by the project Effects of Music Therapy Interventions on the Quality of Life of black women were transcribed. Word cloud, topical modeling and sentiment analysis techniques were employed in this research. Topic modeling identified four groupings of words called “Black Women”, “Reflections”, “Music Therapy” and “Pain”. In turn, sentiment analysis identified a broad distribution of sentiments, with a predominance of neutral or positive sentences, heavily biased to the right and concentrated around the mean, with few extremely negative or positive sentences. These data suggest that the sessions dealt with sentimental issues related to the participating black women and promoted well-being for this population. According to the participants' reports in response to a questionnaire at the end of music therapy sessions, the results of text mining are in line with the participants' perception. In this sense, text mining is a promising technique for understanding verbal communication in music therapy sessions, and can be used in future research to investigate, with more evidence, these and other possibilities for the clinical practice of music therapy.

Keywords: Music therapy. Black women. Text Mining. Mental health.

Introdução

A União Brasileira de Musicoterapia (UBAM, 2018, s/p), define a musicoterapia como “um campo de conhecimento que estuda os efeitos da música e da utilização de experiências musicais, resultantes do encontro entre o/a musicoterapeuta e as pessoas assistidas” e pontua que as práticas musicoterapêuticas podem favorecer o “aumento das possibilidades de existir e agir, seja no trabalho individual, com grupos, nas comunidades, organizações, instituições de saúde e sociedade, nos âmbitos da promoção, prevenção, reabilitação da saúde (...)”.

Podemos inferir, pela definição acima, que musicoterapeutas usam a música como meio para realizar a terapia com uma diversa clientela. No entanto habilidades de comunicação são importantes para as sessões de musicoterapia, especificamente para abrir e fechar sessões, coletar informações e fornecer feedback sobre as experiências musicais dos clientes, estabelecer confiança e facilitar encontros genuínos (GROCKE; WIGRAM, 2007; LINDBLAD, 2016). Algumas técnicas musicoterapêuticas pressupõe que discussões verbais aconteçam, como é o caso da Análise Lírica (SILVERMAN, 2015) ou do Rockumentário (SILVERMAN, 2011). De fato, em abordagens o elemento verbal é fundamentalmente presente como é o caso do Modelo Priestley (1994), por exemplo.

Nolan (2005) delineou a aplicação de técnicas verbais para fornecer clareza sobre a experiência musical, desenvolvendo a consciência do cliente em vários domínios, fornecendo ao terapeuta um meio de obter informações pertinentes sobre o cliente e sobre como proceder. A esse conjunto de técnica denominou processamento verbal: “a fala que facilita o processo terapêutico em resposta ao fazer ou ouvir música” (NOLAN, 2005, p.18).

Ainda que pouco comum na literatura, existem investigações sobre o uso da comunicação verbal (ou processamento verbal) em musicoterapia, como é o caso de Nolan (2005), Gocke e Wigram (2007), Lindblad (2016), Gooding (2017), Schwartz (2019) e Nelligan e McCaffrey (2020). Via de regra, estes textos discutem a importância da comunicação verbal na musicoterapia e apresentam uma série de estratégias para ajudar musicoterapeutas a aprimorar suas habilidades verbais, tais

como a escuta ativa, a empatia e as reflexões. É comum também encontrar nesses textos, vinhetas de atendimentos musicoterapêuticos em que as habilidades de processamento verbal são aplicadas e posteriores sistematizações sobre a integração dessas habilidades na prática clínica musicoterapêutica cotidiana.

No que pese a relevância destas informações para a formação de musicoterapeutas a produção literária acadêmica supracitada não informa como utilizar a comunicação verbal em pesquisas na área de musicoterapia, ou mesmo se é possível sistematizar o contingente comunicacional clínico desta profissão. Uma das formas utilizadas, atualmente, para tratar dados qualitativos em psicoterapia é a mineração de textos, um tipo específico de mineração de dados.

A mineração de dados é um processo de extrair informações válidas antes desconhecidas, de grandes bases de dados, que se utiliza de técnicas como aprendizado de máquinas, estatística e redes neurais e é apoiada no conhecimento indutivo, permitindo descobrir novas regras e padrões nos dados minerados (RABELO; RUBIO, 2018). Kantardzic (2003) informou que o processo de mineração de dados é composto por cinco fases: 1) definição do problema; 2) seleção e coleta dos dados; 3) pré-processamento dos dados; 4) especificação do método; e 5) interpretação e análise dos dados produzidos.

A mineração de textos, também chamada de mineração de dados textuais (text data mining) ou descobrimento de conhecimentos em textos (knowledge discovery in textual databases) é o processo de mineração de dados a fim de buscar ou extrair informações úteis em dados textuais (SILVEIRA JUNIOR; RODRIGUEZ 2022). Assim, a mineração de textos pode lidar com conjuntos de dados não estruturados ou semiestruturados, como e-mails, arquivos HTML e transcrições de entrevistas, dentre outros (GUPTA; LEHAL, 2009). A natureza não estruturada dos dados traz alguns limites para o processo de mineração de textos, dado que nas línguas naturais, as palavras podem revelar diferentes relações que interferirem no significado dos textos; são exemplos a sinonímia, a polissemia e a ambiguidade (RABELO; RUBIO, 2018).

Algumas técnicas comuns à mineração de dados são a nuvem de palavras, a modelagem por tópicos e a análise de sentimento. A Nuvem de Palavras, também conhecida como Word Cloud, é representação gráfica de palavras e termos mais

frequentes em um determinado texto ou conjunto de textos, em que o tamanho da palavra é proporcional à sua frequência. Essa técnica ajuda a identificar padrões e insights de maneira rápida e fácil, permitindo a visualização e compreensão das informações contidas em conjuntos de texto (GUPTA; LEHAL, 2009).

A modelagem de tópicos é uma técnica de aprendizado de máquina de classificação não supervisionada de documentos, semelhante ao agrupamento de dados numéricos, que encontra grupos naturais de itens mesmo quando não temos certeza do que estamos procurando (SILGE; ROBINSON, 2017). A alocação de Dirichlets latentes (Latent Dirichlet allocation – LDA) é um método particularmente popular para ajustar um modelo de tópico que cada documento como uma mistura de tópicos e cada tópico como uma mistura de palavras, o que permite que os documentos “se sobreponham” uns aos outros em termos de conteúdo, em vez de serem separados em grupos distintos, de uma forma que espelha o uso típico da linguagem natural (SILGE; ROBINSON, 2017).

A análise de sentimentos é uma técnica supervisionada de aprendizado de máquina que se concentra na identificação e classificação de opiniões, sentimentos e emoções expressas em textos. Uma maneira de analisar o sentimento de um texto é considerar o texto como uma combinação de suas palavras individuais e o conteúdo de sentimento de todo o texto como a soma do conteúdo de sentimento das palavras individuais (SILGE; ROBINSON, 2017). Essa não é a única maneira de abordar a análise de sentimento, mas é uma abordagem usada com frequência e que se vale de ferramentas organizadas.

São poucos os trabalhos que tratam da interface musicoterapia e mineração de textos. Park et al (2019), por exemplo, construíram um modelo de gerenciamento de conhecimento em musicoterapia a partir da conversão de dados terapêuticos existentes e a tecnologia de mineração de texto. Usando o modelo proposto, casos semelhantes podem ser pesquisados e um tratamento preciso e eficaz pode ser feito para o paciente ou para o cliente com base em dados específicos e confiáveis relacionados ao paciente. No que pese esses achados de Park et al (2019), não achamos pesquisas tratando da produção comunicacional verbal em musicoterapia que utilize da mineração de textos.

Desta forma, o presente estudo tem como objetivo estudar se e como as técnicas de Mineração de Textos podem ser úteis para compreender a comunicação verbal de sessões de musicoterapia. Para tanto, utilizaremos as transcrições de sessões pertencentes ao projeto Efeitos de Intervenções Musicoterapêuticas na Qualidade De Vida de mulheres negras, para verificar quais são as possibilidades e os limites de tais técnicas produzirem material relevante para o entendimento das sessões musicoterapêuticas.

2. Metodologia

Esta é uma pesquisa exploratória, com abordagem quantitativa e qualitativa que usa de técnicas de mineração de textos para extrair informações, identificar padrões e tendências e obter insights a partir das transcrições das sessões do projeto Efeitos de Intervenções Musicoterapêuticas na Qualidade de Vida de mulheres negras, CAAE 55035821.6.0000.5149.

A amostra por conveniência foi de três participantes voluntárias. Os critérios de inclusão foram mulheres autodeclaradas negras, entre 18 e 60 anos de idade, brasileiras residentes na região metropolitana de Belo Horizonte. Os critérios de exclusão foram pessoas menores de 18 anos e maiores de 60 anos, brancas, homens e não brasileiras, não residentes na região metropolitana de Belo Horizonte. O convite para participar dos grupos de Musicoterapia foi divulgado através de publicações tanto nas redes sociais pessoais dos pesquisadores quanto nas redes sociais oficiais do curso de Musicoterapia da UFMG, acessíveis pelos projetos de extensão “Musicoterapia Social em Minas Gerais” (SIEX UFMG 402283) e “Construção do Site de Musicoterapia” (SIEX UFMG 402833), coparticipantes da pesquisa.

Os atendimentos ocorreram nas dependências da Escola de Música da UFMG, em grupo, com a frequência de uma sessão por semana, com duração de uma hora, durante dois meses. Todos os procedimentos foram comunicados previamente às participantes e deferidos por meio do Termo de Consentimento Livre e Esclarecido (TCLE), incluindo a gravação das sessões. No que pese as participantes terem

preenchido instrumentos de avaliação padronizados e com evidências de validade e confiabilidade em português brasileiro trataremos aqui apenas do que foi comunicado verbalmente durante as sessões e posteriormente transcrito.

Para realizar as análises de mineração de textos com o material transcrito utilizamos o software R v. 4.2.0 (R CORE TEAM, 2022) e a interface gráfica do utilizador (Graphical User Interface – GUI) RStudio. Para limpeza do corpus valemos do pacote `tm` v. 0.8. (FEINERER; HORNIK, 2020). Para gerar nuvem de palavras usamos o pacote `wordcloud2` v. 0.2.1 (LANG; CHIEN, 2018). Para a modelagem de tópicos lançamos mão do pacote `ldatuning` v. 1.0.2 (NIKITA, 2020) a fim de verificar qual o melhor modelo e o pacote `topicmodels` v.0.2.12 (GRÜN; HORNIK, 2011) a fim de realizar a modelagem por tópicos com LDA. A análise de sentimento foi feita a partir do pacote `sentimentr` v. 2.9.0 (RINKER, 2021), que possui suporte para textos em português.

Além de pacotes com tarefas específicas, lançamos mão, também, do pacote `ggplot2` v.3.3.6 (WICKHAM, 2016) para gerar imagens da modelagem de tópicos e da análise de sentimento e os pacotes `tidytext` v. 0.4.1 (SILGE; ROBINSON, 2016), `dplyr` v. 1.0.9 (WICKHAM et al, 2022), e `psych` v. 2.2.5 (REVELLE, 2022) que auxiliaram na operacionalização das funções dos pacotes supracitados.

3. Resultados

Inicialmente seis mulheres se voluntariaram, mas apenas três participaram do projeto, para as quais utilizaremos nomes fictícios de Dandara, Aqualtune e Luísa Mahin. A média de idade das participantes foi de 25,7 (DP = 6), nenhuma delas já havia participado de um atendimento musicoterapêutico, duas possuíam algum nível de estudo musical. Seus instrumentos musicais prediletos eram violão, piano, violino e voz. Todas as mulheres se identificaram com a música popular brasileira (MPB), estilo musical mais utilizado nos atendimentos com um forte apelo para canções (músicas que possuem letras). Ao serem questionadas se já foram vítimas de racismo e/ou práticas machistas, todas as participantes responderam sim.

As oito sessões iniciaram e encerraram com canções que abordavam individualmente as participantes, abrindo espaço para que apresentassem seus

nomes e/ou tocassem instrumentos sozinhas. O contato entre as mulheres foi fortificado e a confiança e autoestima trabalhadas durante as sessões. As sessões trabalharam com as técnicas de análises lírica de canções (SILVERMAN, 2015), bem como composição de paródia e de canção sem estrutura preexistente (BRUSCIA, 2016). Também foram utilizados improvisos vocais, onde as participantes cantavam sobre o que haviam discutido, de forma livre, compondo sem restrições ou necessidades de registro (BRUSCIA, 2016).

As participantes preencheram as escalas DASS-21 (VIGNOLA, 2013) e WHOQOL-bref (FLECK *et al*, 2000) no início e ao fim dos atendimentos e responderam questionários no início e no fim dos atendimentos. O primeiro questionário foi relevante para levantar questões sobre a identidade sonora das participantes e o questionário final para receber um feedback sobre os atendimentos. Gravamos as sessões, da segunda sessão até a sétima, e, posteriormente as transcrevamos. A partir destas transcrições utilizamos técnicas de mineração de dados, que reportaremos a seguir.

3.1. Preparação e limpeza do texto

O processo de limpeza da transcrição dos atendimentos se deu com o pacote *tm* (FEINERER; HORNIK, 2020), a partir de funções específicas para armazenar e transformar o texto em apenas um vetor do tipo "VCorpus", uma classe de *corpus* vetorizado, onde cada elemento do *corpus* é um documento individual (RIBEIRO, 2017). A função permite a aplicação de etapas de pré-processamento do texto, como remoção de pontuação, de números, de *stopwords*³ e espaços em branco extra. Por fim, convertemos todas as letras maiúsculas em minúsculas.

Considerando que a nuvem de palavras é um gráfico que permite a rápida visualização dos termos mais frequentes, a imagem que segue na figura 1 foi gerada, a partir do pacote *wordcloud2* a fim de visualizar o *corpus*.

³ *Stopwords* são palavras muito comuns em um idioma, mas que geralmente não possuem significado por si só. Essas palavras são consideradas irrelevantes para a análise de texto, pois aparecem com muita frequência em um *corpus* e não adicionam informações relevantes sobre o contexto ou a intenção do autor. Exemplos de *stopwords* em português são "de", "a", "o", "que", "e", "para", entre outras. O pacote *tm* oferece uma lista com 203 *stopwords* em português.

3.2. Modelagem por tópicos

Antes de realizar a modelagem por tópicos realizamos o teste que calcula diferentes métricas para estimar o número preferível de tópicos para um modelo LDA a partir da função FindTopicsNumber do pacote ldatuning (NIKITA, 2020). Seleccionamos as métricas "Griffiths2004" que avalia a probabilidade de as palavras ocorrerem juntas em um tópico (métrica de coerência), "CaoJuan2009" que avalia a distinção entre tópicos (métrica de exclusividade), "Arun2010" que considera tanto a coerência quanto a exclusividade dos tópicos e a métrica "Deveaud2014" avalia a capacidade do modelo criar tópicos distintos e bem definidos, com alta probabilidade de palavras específicas desse tópico e baixa probabilidade de palavras comuns a outros tópicos (métrica da qualidade da modelagem de tópicos).

As medidas Arun2010 e CaoJuan2009 devem ser minimizadas, enquanto as medidas Deveaud2014 e Griffiths2004 devem ser maximizadas. No entanto, como as medidas Arun2010 e CaoJuan2009 geralmente diminuem com o número de tópicos, e as medidas Deveaud2014 e Griffiths2004 aumentam com o número de tópicos, escolhemos o número de tópicos quando as medidas observadas começarem a convergir, em quatro tópicos (figura 2).

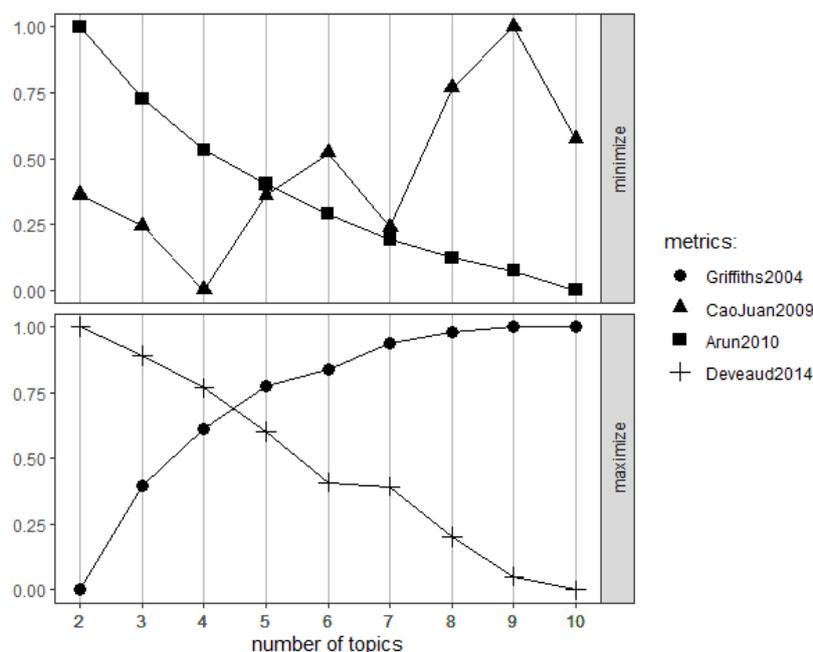


Figura 2: Métricas para estimativa do número de tópicos mais adequado.

Ao gerar a modelagem de tópicos pela função LDA do pacote topicmodels (GRÜN; HORNIK, 2011), utilizando os 10 termos mais frequentes em cada tópico, encontramos a seguinte configuração:



Figura 3: Modelagem por tópicos, contendo as 10 palavras mais recorrentes em cada tópico.

Em uma modelagem por tópicos utilizando o algoritmo LDA, "beta" representa a probabilidade de uma determinada palavra estar presente em um determinado tópico. Como a modelagem por tópicos é um método de classificação não supervisionado podemos dar um rótulo para cada tópico a partir das palavras que o compõem:

- **Tópico 1: Mulheres Negras** – se refere às questões que afetam as mulheres negras, agrupando palavras como "mulher", "mulheres", "negra" e "negras". Termos como "sentimento" e "falar" sugerem expressões de questões pessoais a

partir das músicas utilizadas na sessão, além de questões de identidade, autoestima e empoderamento;

- **Tópico 2: Reflexões** – está mais relacionado a reflexões e questionamentos, com palavras como "acho", "hoje" e "mundo", indicando conversas sobre as experiências pessoais da terapeuta e dos pacientes;

- **Tópico 3: Musicoterapia** – se relaciona diretamente ao processo musicoterapêutico, com termos como "jeniffer", "dandara", "fala" e "música". Refere-se às técnicas utilizadas pela estagiária durante os atendimentos;

- **Tópico 4: Dores** – as expressões "fala", "música", "incomoda" e "dores" indicam que este tópico se conecta com questões sentimentais das participantes dos atendimentos e apontam para conversas sobre a utilização da música como ferramenta terapêutica para lidar com essas questões.

Como foram recorrentes as palavras relacionadas às questões emocionais, tais como dores e incômodos de ser uma mulher negra, optamos por realizar uma Análise de Sentimento (SLIGE; ROBINSON, 2017), para verificar qual foi o sentimento recorrente das sessões de musicoterapia.

3.3. Análise de sentimento

A análise de sentimentos encontrou 244 frases, com a média de palavra 27 palavras em cada frase. Esta técnica pontua valores entre -1 a 0 para frases com palavras negativas, 0 para frases com palavras neutras e valores entre 0 e 1 frases com palavras com valores positivos. O gráfico da figura 4 gera uma imagem em que é possível observar que o número de frases positivas (> 0) foi maior e teve mais intensidade do que as frases negativas (< 0).

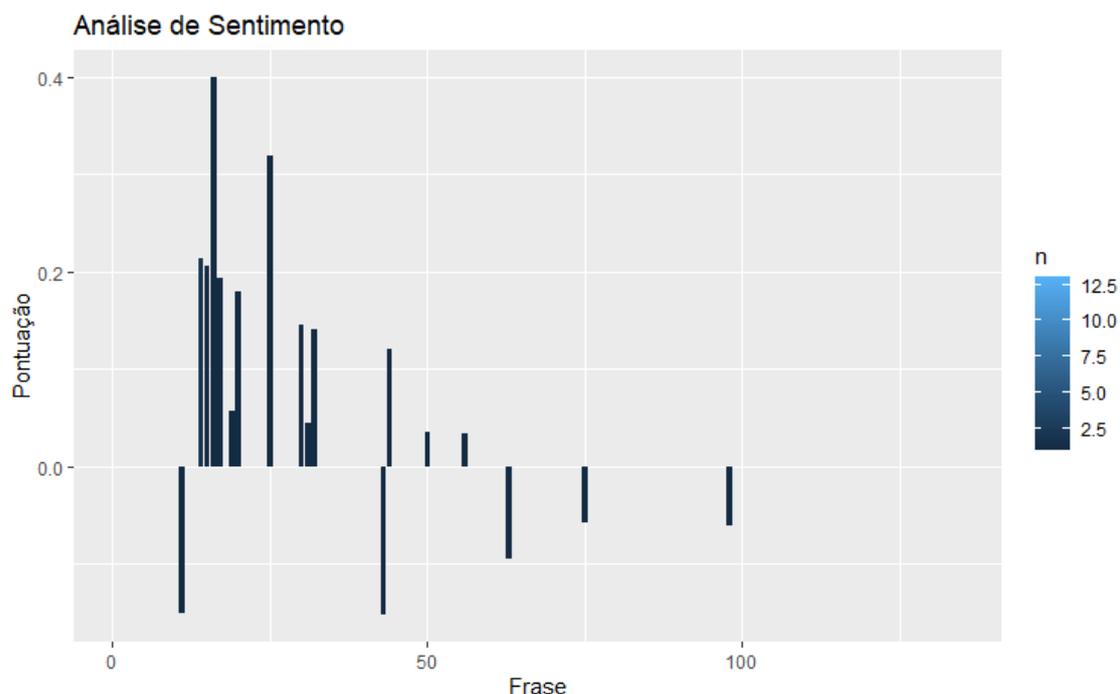


Figura 4: Análise de sentimento

A análise de sentimentos revelou uma soma total de 1,76 para o texto ($M = 0,007$, $DP = 0,05$), indicando uma distribuição ampla de sentimentos, porém com predominância de sentenças neutras ou positivas, uma vez que a mediana (assim como a média) se aproxima de zero e o valor máximo positivo foi de 0,4, enquanto o valor mínimo negativo foi de -0,15. Além disso, os dados da assimetria (4,41) e da curtose (27,94) corroboram a predominância de sentenças positivas, sugerindo que a distribuição é fortemente enviesada para a direita e concentrada em torno da média, com poucas sentenças extremamente negativas ou positivas.

4. Considerações finais

Com base nos dados referentes à modelagem por tópicos e na análise de sentimentos, é possível inferir algumas informações relevantes sobre as sessões de musicoterapia com mulheres negras. Os tópicos indicam que as participantes e a estagiária discutiram suas experiências pessoais relacionadas à identidade,

autoestima e empoderamento, com reflexões e questionamentos a partir do processo musicoterapêutico e das técnicas utilizadas durante as sessões. Isso sugere que a música foi uma parte fundamental da terapia e que a estagiária teve um papel importante no processo.

O quarto tópico se relaciona com questões sentimentais das participantes, indicando que a música foi utilizada como uma ferramenta terapêutica para lidar com essas questões. Isso é reforçado pela presença de termos como "incomoda" e "dores", sugerindo que as participantes podem ter abordado questões emocionais e utilizaram a música como uma forma de lidar com essas questões. Por isso, realizamos a análise de sentimentos que teve como resultado um valor médio positivo (0,007), indicando que as frases foram predominantemente neutras em termos de sentimento. No entanto, é importante lembrar que a análise de sentimentos é uma ferramenta limitada e pode não capturar nuances e complexidades emocionais presentes nas sessões, como figura de linguagens, por exemplo.

Em resumo, os atendimentos musicoterapêuticos às três mulheres negras foram centrados em questões pessoais, reflexões e questionamentos, com a música sendo uma ferramenta fundamental para abordar questões emocionais e lidar com as dores das participantes. A estagiária Jeniffer teve um papel importante no processo, utilizando técnicas específicas de musicoterapia para ajudar as participantes a expressar suas emoções e lidar com seus sentimentos.

Os dados aqui apresentados são coerentes com as respostas das participantes ao questionário final, em que relataram que os benefícios principais percebidos pelas sessões foram "leveza", "capacidade de olhar para as dores de frente", "refletir sobre várias questões e aprender a não sofrer com certos gatilhos", "consciência e melhor compreensão das dores" e "justificativa de sentimentos de tristeza antes sem fundamento".

Pesquisa posterior investigará os resultados da aplicação das escalas DASS-21 e WHOQOL-bref para indicar, com mais evidências, se as técnicas de mineração de textos apontaram na mesma direção dos instrumentos de avaliação que já possuem evidências de validade e confiabilidade. No que conseguimos avaliar neste estudo, a mineração de textos apresenta um caminho promissor para tratar o material relativo

à comunicação verbal em sessões de musicoterapia.

Referências

BRUSCIA, Kenneth, E. **Definindo musicoterapia**. Tradução: Marcus Leopoldino. Barcelona: Barcelona Publishers, 3 ed, 2016.

FLECK, M.P.A.; LOUZADA, S.; XAVIER, M.; CHAMOVICH, E.; VIEIRA, G.; SANTOS, L.; PINZON V. **Aplicação da versão em português do instrumento abreviado de avaliação da qualidade de vida “WHOQOL-bref”**. Revista de saúde pública, v.34, n.2, p. 178-183, 2000.

GOODING, L. F. **Microskills training: A model for teaching verbal processing skills in music therapy**. Voices: A World Forum for Music Therapy, v.17, n.1, p.1-10, 2017. Doi: <https://doi.org/10.15845/voices.v17i1.894>.

GROCKE, D.; WIGRAM, T. **Receptive methods in music therapy: Techniques and clinical applications for music therapy clinicians, educators and students**. London and Philadelphia: Jessica Kingsley, 2007.

GRÜN, B.; HORNIK, K. **“topicmodels: An R Package for Fitting Topic Models.”** Journal of Statistical Software, v.40, n.13, p.1-30. doi:10.18637/jss.v040.i13 <https://doi.org/10.18637/jss.v040.i13>.

KANTARDZIC, M. **Data mining: Concepts, models, methods, and algorithms**. Hoboken, Nova Jersey, EUA: John Wiley & Sons Inc, 2003.

LANG, D.; CHIEN, G. **wordcloud2: Create Word Cloud by 'htmlwidget' (version 0.2.1)**. [R package], 2018. In: <https://CRAN.R-project.org/package=wordcloud2>.

LINDBLAD, K. **Verbal dialogue in music therapy: A hermeneutical analysis of three music therapy sessions**. Voices: A World Forum for Music Therapy, v.16, n.1, 2016. Doi: <https://doi.org/10.15845/voices.v16i1.842>.

NELLIGAN, S.; MCCAFFREY, T. **An Investigation of Music Therapists’ Experiences of Verbal Dialogue in Music Therapy Sessions**. Voices: A World Forum for Music Therapy, v.20, n.1, 2020, p. 1-15. <https://doi.org/10.15845/voices.v20i1.2868>.

NIKITA, M. **ldatuning: Tuning of the Latent Dirichlet Allocation Models Parameters (version 1.0.2)**. [R package], 2020. In: <https://CRAN.R-project.org/package=ldatuning>.

NOLAN, P. **Verbal processing within the music therapy relationship**. Music Therapy Perspectives, v.23, n.1, p.18-28, 2005. Doi: <https://doi.org/10.1093/mtp/23.1.18>.

PANDUR, M. B.; DOBŠA, J.; BELIGA, S.; MEŠTROVIĆ, A. **Topic modelling and sentiment**
Revista InCantare
vol. 16 no. 1. jan-jun-2022
ISSN: 2317-417X / Curitiba

analysis of COVID-19 related news on Croatian Internet portal. Proceedings of the 23rd International Multiconference Information Society, 5–9 October 2020, Ljubljana, Slovenia.

PARK, S.-H., KIM, J.-W., KIM, D.-H., & CHO, H.-J. **A Study on the Music Therapy Management Model Based on Text Mining.** Journal of the Korea Convergence Society, v.10, n.8, p.15–20, 2019. Doi: <https://doi.org/10.15207/JKCS.2019.10.8.015>.

PRIESTLEY, M. **Essays on analytic music therapy.** Barcelona: Barcelona Publishers, 1994.

RABELO, I.S.; RUBIO, K. **Literatura científica sobre a mineração de textos aplicada à identificação da personalidade de atletas.** Olimpianos –Journal of Olympic Studies, v.2, n.1, p.274-303, 2018. Doi: <https://doi.org/10.30937/2526-6314.v2n1.id37>.

R CORE TEAM. **R: A language and environment for statistical computing.** R Foundation for Statistical Computing [Computer software]. Vienna, Austria, 2022. <https://www.R-project.org/>.

REVELLE, W. **psych: Procedures for Personality and Psychological Research,** Northwestern University, Evanston, Illinois, USA, 2022. In: <https://CRAN.R-project.org/package=psych>.

RIBEIRO, A. C. M. **Análise de atividade de instituições de ensino superior em redes sociais.** Dissertação (Faculdade de Ciências). Universidade do Porto: Porto-Portugal, 2017. In: <https://repositorio-aberto.up.pt/bitstream/10216/110671/2/250622.pdf>. Acesso: 17/04/2022.

RINKER, T. W. (2021). **sentimentr: Calculate Text Polarity Sentiment version 2.9.0.** In: <https://github.com/trinker/sentimentr>. Acesso: 17/04/2022.

SCHWARTZ, E. K. **Basic verbal skills for music therapists.** Barcelona: Barcelona Publishers, 2019.

SILGE, J.; ROBINSON, D. **tidytext: Text Mining and Analysis Using Tidy Data Principles** in R. JOSS, v.1, n.3, p.1-3, 2016. Doi: <https://doi.org/10.21105/joss.00037>, <http://dx.doi.org/10.21105/joss.00037>.

SILGE J., ROBINSON D. **Text mining with R: A tidy approach.** Sebastopol, CA: O'Reilly Media, 2017.

SILVEIRA JUNIOR, R. R.; RODRIGUEZ, D. L. **Mineração de dados: um olhar instigante de possibilidades e aplicações para órgãos da administração pública federal.** Revista do Serviço Público - RSP, v. 73, n. 3, p. 451-478, 2022. In: <https://revista.enap.gov.br/index.php/RSP/article/view/5446/5135>. DOI: <https://doi.org/10.21874/rsp.v73.i3.5446>.

SILVERMAN, M. J. **Effects of music therapy on change readiness and cravingin**

patients on a detoxification unit. Journal of Music Therapy, Oxford, England, v. 48, n. 4, p. 509-531, 2011. Disponível em: <https://doi.org/10.1093/jmt/48.4.509>. Acesso em: 3/12/2020.

SILVERMAN, M. J. **Effects of Lyric Analysis Interventions on Treatment Motivation in Patients on a Detoxification Unit: A Randomized Effectiveness Study.** Journal of Music Therapy, Oxford, England, v. 52, n. 1, p. 117-134, 2015. Disponível em: <https://doi.org/10.1093/jmt/thu057>. Acesso em: 3/12/2020.