



Análise de Dados para Avaliação dos Efeitos da Música na Saúde Mental: Um Estudo com Algoritmos de Classificação Supervisionada

Ana Luiza Oliveira de Macedo

Universidade Federal do Vale do São Francisco – UNIVASF

(luiza.oliveira@discente.univasf.edu.br)

Thiago Magalhães Amaral

Universidade Federal do Vale do São Francisco – UNIVASF

(thiago.magalhaes@univasf.edu.br)

CONTEXTUALIZAÇÃO: Ao longo da história, a música tem sido utilizada como instrumento de cura, terapia e bem-estar (MACDONALD et al., 2012). Por consequência de ser amplamente reconhecida como um fator capaz de influenciar estados emocionais e cognitivos, é utilizada como um método de intervenção terapêutica em diferentes contextos de saúde mental (YIN, 2021). Uma possível abordagem sugere que a preferência por determinados estímulos musicais pode inclusive influir na percepção temporal, baseando-se em evidências de que sentimentos positivos podem interferir na forma como a compreensão intelectual é processada e organizada para formar a percepção cognitiva (ASHBY; ISEN; TURKEN, 1999). Em adição, alguns estudos apontam ainda que gêneros musicais distintos podem estar associados a efeitos positivos, neutros ou até negativos percebidos em condições relacionadas a saúde mental, como: ansiedade, depressão, Transtorno Obsessivo Compulsivo (TOC) e qualidade do sono (MONTEIRO et al., 2020). Nesse cenário, sugere-se a utilização de técnicas de aprendizado supervisionado para a classificação de padrões associados aos hábitos musicais e seus efeitos percebidos na saúde mental. Por fim, ressalta-se ainda a importância do uso de algoritmos de *machine learning* no contexto de apoio à Pesquisa Operacional (PO),



Anais do Simpósio Acadêmico de Engenharia de Produção (SAEPRO) da EEL-USP

IX SAEPRO – 25 e 26 de novembro de 2025

sobretudo na modelagem e análise de problemas complexos na área da saúde, assegurando a tomada de decisões consistentes e eficientes, baseadas em padrões extraídos de dados reais.

OBJETIVO: Desenvolver um modelo de *machine learning* para classificar padrões percebidos entre consumo musical (como gêneros, frequência e preferências) e a percepção de impacto na saúde mental (melhora, ausência de efeito ou piora), com base em dados autorreferidos e características individuais dos participantes.

MÉTODO: Para o desenvolvimento deste estudo, utilizou-se um banco de dados denominado *Mental Health & Music Relationship*, contendo 736 respostas e 33 variáveis, incluindo idade, tempo diário de escuta, serviço de streaming, gênero favorito, frequência de escuta de diferentes estilos musicais e indicadores de saúde mental (ansiedade, depressão, insônia e TOC). O pré-processamento envolveu o tratamento de valores ausentes, a conversão de variáveis categóricas para variáveis numéricas que pudessem ser avaliadas através dos algoritmos de análise, a normalização de variáveis numéricas e a seleção da variável-alvo, denominada de “Music effects”. Para o procedimento foram comparados os resultados obtidos para a aplicação dos algoritmos KNN e *Random Forest*, através do método de validação cruzada com 10 divisões (*10-fold cross-validation*). Vale ressaltar ainda que o modelo KNN foi configurado com diferentes valores de k (3, 5, 7 e 11), todos a partir da métrica euclidiana com peso uniforme. Por sua vez, o *Random Forest* foi configurado com 50 árvores, treinamento replicável ativado e divisão mínima de 5 exemplos por nó. Por fim, as métricas consideradas durante a avaliação dos modelos incluíram a acurácia (CA), a área sob a curva ROC (AUC), F1 score e a matriz de confusão gerada.

RESULTADOS E DISCUSSÕES: A avaliação comparativa dos modelos de classificação supervisionada testados revelou ligeiras variações no desempenho. Entre os valores de k aplicados ao método KNN, observou-se que os resultados apresentaram desempenhos com variações moderadas, relativas a taxas de acurácia variando entre cerca de 67% e 73%. Vale destacar ainda que o KNN com $k = 7$ obteve uma discreta vantagem em termos de acurácia, com 73,1%, e F1 score, com 65%, enquanto o KNN com $k = 3$



Anais do Simpósio Acadêmico de Engenharia de Produção (SAEPRO) da EEL-USP

IX SAEPRO – 25 e 26 de novembro de 2025

demonstrou um desempenho reduzido, relativo a um maior índice de erros de classificação entre as classes. Por sua vez, o *Random Forest* apresentou a maior taxa de acurácia (75,6%) dentre os métodos aplicados, além de demonstrar um desempenho consistente na identificação da classe majoritária. A partir dos resultados obtidos, nota-se ainda que as matrizes de confusão indicam uma tendência comum em todos os modelos: forte predominância na predição da categoria de percepção de melhora associada ao consumo de música, acompanhada de dificuldades na diferenciação entre as categorias de piora do quadro de saúde mental e ausência de efeito associada à prática. Contudo, considerando que a interpretação individual dos efeitos da música pode variar significativamente entre os entrevistados, tornando a linha entre “ausência de efeito” e “melhora leve” muito discreta, uma possível influência da subjetividade dos relatos coletados pode estar associada a dificuldade apresentada pelos algoritmos de classificação distinguir essa captura. Em resumo, os resultados apontam que tanto o KNN quanto o *Random Forest* são capazes de capturar parcialmente os padrões de associação entre preferências musicais e efeitos percebidos na saúde mental. Apesar disso, a forte concentração de predições na categoria de melhora reflete a tendência a favorecer percepções positivas. Neste cenário, reforça-se a aplicabilidade de estratégias complementares, como a coleta de dados mais objetivos ou uso de algoritmos mais sensíveis a variações sutis, de modo a melhorar a imparcialidade da classificação entre todas as categorias.

CONSIDERAÇÕES FINAIS: O presente trabalho demonstrou como a aplicação de modelos de *machine learning* pode auxiliar na avaliação de padrões percebidos através do consumo de música sobre a percepção da saúde mental avaliada por indivíduos entrevistados. O estudo reforça a viabilidade da aplicação do KNN e do *Random Forest*, assim como de muitos outros algoritmos disponíveis, através de *softwares* visuais e mais intuitivos como o Orange, no contexto da aprendizagem supervisionada. Com base nos resultados apresentados para o estudo de classificação dos efeitos percebidos do consumo de música sobre a saúde mental, percebe-se um desempenho satisfatório, em especial para o *Random Forest* e para o KNN com $k = 7$, que obtiveram resultados ligeiramente



Anais do Simpósio Acadêmico de Engenharia de Produção (SAEPRO) da EEL-USP

IX SAEPRO – 25 e 26 de novembro de 2025

próximos entre si e superiores aos demais algoritmos testados. Menciona-se, ainda, que em comparação com estudos publicados no Kaggle (plataforma online voltada para estudos da ciência de dados), que utilizam o mesmo banco de dados, o presente trabalho demonstra um avanço na investigação das interações entre música e saúde mental ao propor a aplicação de algoritmos de aprendizagem supervisionada, enquanto os demais concentram-se predominantemente em análises exploratórias, caracterizados pela utilização de representações gráficas para compreensão do comportamento das variáveis. Por fim, sugere-se, em trabalhos futuros, a ampliação da base de dados, bem como a exploração de algoritmos mais robustos e a seleção de dados objetivos para a composição do banco de dados, buscando reduzir subjetividades nas respostas e facilitar a captura de padrões pelos algoritmos utilizados.

PALAVRAS-CHAVE: Música; Saúde Mental; KNN; Random Forest; Orange.

REFERÊNCIAS:

ASHBY, F. G.; ISEN, A. M.; TURKEN, A. U. *A neuropsychological theory of positive affect and its influence on cognition*. *Psychological Review*, v. 106, n. 3, p. 529-550, 1999.

KAGGLE. *Mental Health & Music Relationship: Analysis & EDA*. Kaggle Datasets, 2024. Disponível em: <https://www.kaggle.com/code/melissamonfared/mental-health-music-relationship-analysis-eda>.

YIN, Zhuoran. *Research on the application of music-based psychological adjustment in improving postgraduates' mental health*. *Revista Brasileira de Medicina do Esporte*, v. 27, edição especial, p. 43-46, jan./fev./mar. 2021. DOI: 10.1590/1517-8692202127012020_0108.

MACDONALD, R.; KREUTZ, G.; MITCHELL, L. (Org.). *What is Music, Health and Wellbeing and Why is it Important?*. Oxford: Oxford University Press, 2012.



Anais do Simpósio Acadêmico de Engenharia de Produção (SAEPRO) da EEL-USP

IX SAEPRO – 25 e 26 de novembro de 2025

MARQUES, Paula Alexandra Ramalho. *A influência da música na saúde mental e bem-estar: um estudo exploratório*. 2017. Dissertação (Mestrado em Psicologia Clínica e da Saúde) – Universidade Fernando Pessoa, Porto, 2017.

MONTEIRO, R. P., COELHO, G. L. d. H., VILAR, R., ANDRADE, W. S. B., & PIMENTEL, C. E. (2021). *Indirect effects of preference for intense music on mental health through positive and negative affect*. *Psychology of Music*, 49(6), 1737–1746, 2020.

ORANGE DATA MINING. *Orange – Data Mining Fruitful & Fun*. 2024. Disponível em: <https://orangedatamining.com/>.

SILVA, Júlio. *Inteligência artificial e música*. 2023. 51 f. Trabalho de Conclusão de Curso (Bacharelado em Música – Habilitação em Composição) – Escola de Comunicações e Artes, Universidade de São Paulo, São Paulo, 2023.

SIMANGUNSONG, Juanto; SIMANJUNTAK, Mutiara S.; SIMANJUNTAK, Nurmala Dewi. *Mental disorder classification with exploratory data analysis (EDA)*. *Journal of Intelligent Decision Support System (IDSS)*, v. 7, n. 3, p. 210–217, set. 2024. Disponível em: <https://www.idss.iocspublisher.org>.

SUN, Jingjing; YANG, Jingyi; ZHOU, Guyue; JIN, Yucheng; GONG, Jiangtao. *Understanding Human-AI Collaboration in Music Therapy Through Co-Design with Therapists*. In: *CHI Conference on Human Factors in Computing Systems (CHI '24)*, 2024, Honolulu, HI, USA. New York: ACM, 2024. DOI: 10.1145/3613904.3642764.

VAN WIJCK, C. *Music and health: current perspectives*. 2012.