



UNIVERSIDADE FEDERAL DE PERNAMBUCO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA BIOMÉDICA

ESTUDO DE SELEÇÃO DE ATRIBUTOS APLICADO AO
RECONHECIMENTO DE EMOÇÕES EM SINAIS MULTIMODAIS COMO
APOIO À MUSICOTERAPIA

RECIFE 2024

WILZA OLIVEIRA DOS SANTOS

**ESTUDO DE SELEÇÃO DE ATRIBUTOS APLICADO AO
RECONHECIMENTO DE EMOÇÕES EM SINAIS MULTIMODAIS COMO
APOIO À MUSICOTERAPIA**

Trabalho submetido ao Programa de Pós-Graduação em Engenharia Biomédica da Universidade Federal de Pernambuco como requisito parcial para obtenção do grau de Mestra em Engenharia Biomédica.

Área de Concentração: Computação Biomédica

Orientador: Wellington Pinheiro dos Santos

Coorientadora: Maíra Araújo de Santana

RECIFE 2024

.Catalogação de Publicação na Fonte. UFPE - Biblioteca Central

Santos, Wilza Oliveira dos.

Estudo de seleção de atributos aplicado ao reconhecimento de emoções em sinais multimodais como apoio à musicoterapia / Wilza Oliveira dos Santos. - Recife, 2024.

65f.: il.

Dissertação (Mestrado) - Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Programa de Pós-Graduação em Engenharia Biomédica, 2024.

Orientação: Wellington Pinheiro dos Santos.

Coorientação: Maíra Araújo de Santana.

Inclui referências.

1. Doença de Alzheimer; 2. Demência; 3. Eletroencefalografia; 4. Musicoterapia; 5. Computação Afetiva; 6. Inteligência Artificial. I. Santos, Wellington Pinheiro dos. II. Santana, Maíra Araújo de. III. Título.

UFPE-Biblioteca Central

AGRADECIMENTOS

A Deus, por estar sempre comigo e por me ajudar a ultrapassar todos os obstáculos que surgiram ao longo da Pós-Graduação.

Aos meus Pais, por todo o incentivo e, principalmente por me ensinarem que é o conhecimento, o estudo que nos move a ir mais longe na busca dos nossos objetivos e por sempre me motivarem a nunca desistir e estudar.

Ao meu orientador, Wellington Pinheiro e a minha coorientadora, Maíra Araújo por todo cuidado e incentivo, pela paciência, confiança e pela disponibilidade de me acompanharem dando todo o auxílio e suporte necessário para o desenvolvimento dessa dissertação.

Aos professores, pelos seus ensinamentos e contribuições para essa dissertação.

A todos que participaram da pesquisa, pela colaboração, convivência e conhecimentos compartilhados.

Agradeço, por fim, a todos que me apoiaram durante a realização deste trabalho.

RESUMO

O envelhecimento da população brasileira, impulsionado pela queda na taxa de natalidade e pelo aumento da expectativa de vida, traz consigo um aumento na prevalência de doenças como osteoporose, hipertensão e demências, especialmente a Doença de Alzheimer e a isquemia cerebrovascular. Nesse contexto, a musicoterapia surge como um potencial aliado no combate aos efeitos dessas doenças, demonstrando ser capaz de desacelerar o progresso das demências através de estímulos musicais e da educação musical. A interação do paciente com a música promove a estimulação de áreas cerebrais relacionadas à memória, utilizando as emoções como meio de ativação. No entanto, a efetividade da musicoterapia depende crucialmente da capacidade do terapeuta em reconhecer e estimular corretamente as emoções do paciente. Diante da necessidade de aprimorar a efetividade da musicoterapia, esta pesquisa propõe o desenvolvimento de uma interface musical cérebro-máquina (IMC-M) baseada em redes neurais artificiais profundas (RNA) e algoritmos evolutivos, com o objetivo de reconhecer as emoções do paciente a partir de sinais eletroencefalográficos (EEG) e da voz, permitindo a personalização dos estímulos musicais na musicoterapia em idosos. Esta dissertação de mestrado teve como objetivo geral desenvolver um modelo robusto para o reconhecimento de emoções em idosos, utilizando sinais de EEG e voz. Os resultados obtidos nesta pesquisa demonstram que o objetivo geral foi atingido. A base de dados coletada é uma das maiores e mais completas na área de reconhecimento de emoções em idosos até o momento, e o modelo desenvolvido apresentou um alto desempenho na classificação das emoções, com valores de acurácia superiores a 99%. Os métodos de classificação utilizados para serem investigados foram: o Bayes Net, Naive Bayes, árvore de decisão J48, Random Tree e Random Forest (100, 200, 300, 400 e 450 árvores). O classificador Random Forest foi o que apresentou um melhor desempenho dentre as bases. A seleção de atributos utilizando PSO contribuiu para a redução da complexidade do modelo e para a melhoria do seu desempenho. O modelo desenvolvido nesta dissertação tem potencial para ser aplicado em diferentes contextos, como no cuidado com idosos, na interação homem-máquina e na pesquisa científica. O uso do modelo pode auxiliar na identificação de alterações de humor em idosos, na avaliação do impacto de intervenções terapêuticas e no desenvolvimento de interfaces mais intuitivas e personalizadas para interação com essa população. A implementação da IMC-M na musicoterapia em idosos tem o potencial de transformar o tratamento de pacientes com demências e outras doenças relacionadas à idade. Através do reconhecimento preciso das emoções do paciente, a IMC-M permite a personalização dos estímulos musicais, otimizando a efetividade da musicoterapia e promovendo uma experiência terapêutica mais individualizada e eficaz. Além disso, a pesquisa contribui para o avanço do conhecimento sobre as relações entre música, emoções e o cérebro humano em idosos, abrindo caminho para novas aplicações na musicoterapia e em outros domínios da saúde voltados para essa população.

Palavras-chave: Doença de Alzheimer, Computação Afetiva, Musicoterapia, Demência, Cognição, Inteligência Artificial, Eletroencefalografia.

ABSTRACT

The aging Brazilian population, driven by declining birth rates and rising life expectancy, has led to a surge in age-related diseases, particularly dementias like Alzheimer's disease and stroke. In this context, music therapy emerges as a promising tool to combat the effects of these conditions, demonstrating its ability to slow dementia progression through musical stimuli and musical education. Patient interaction with music promotes the stimulation of brain areas related to memory, using emotions as a means of activation. However, the effectiveness of music therapy crucially depends on the therapist's ability to accurately recognize and elicit patient emotions. To address this challenge, this research proposes the development of a brain-computer music interface (BCMI) based on deep artificial neural networks (ANNs) and evolutionary algorithms, with the aim of recognizing patient emotions from electroencephalographic (EEG) signals and voice, enabling the personalization of musical stimuli in music therapy for elderly people. This master's dissertation aimed to develop a robust model for emotion recognition in elderly people, using EEG and voice signals. The results obtained in this research demonstrate that the general objective was achieved. The collected database is one of the largest and most complete in the field of emotion recognition in elderly people to date, and the developed model presented high performance in emotion classification, with accuracy values above 99%. The classification methods used for investigation were: Bayes Net, Naive Bayes, J48 decision tree, Random Tree and Random Forest (100, 200, 300, 400 and 450 trees). The Random Forest classifier performed best among the bases. The selection of attributes using PSO contributed to the reduction of the model's complexity and the improvement of its performance. The model developed in this dissertation has the potential to be applied in different contexts, such as elderly care, human-machine interaction, and scientific research. The use of the model can assist in identifying mood changes in elderly people, evaluating the impact of therapeutic interventions, and developing more intuitive and personalized interfaces for interaction with this population. Implementing the BCMI in music therapy for elderly people has the potential to transform the treatment of patients with dementia and other age-related diseases. Through accurate recognition of patient emotions, the BCMI enables the personalization of musical stimuli, optimizing the effectiveness of music therapy and promoting a more individualized and effective therapeutic experience. In addition, the research contributes to the advancement of knowledge about the relationships between music, emotions, and the human brain in elderly people, paving the way for new applications in music therapy and other health domains focused on this population.

Keywords: Alzheimer's Disease, Affective Computing, Music Therapy, Dementia, Cognition, Artificial Intelligence, Electroencephalography.

SUMÁRIO

Lista de Figuras	08
Lista de Tabelas	09
1. Introdução	10
2. Objetivos	13
2.1 Organização do Trabalho	13
3. Referencial Teórico	14
3.1 Inteligência Artificial	14
3.1.1 Histórico	15
3.1.2 Tipos de Aplicação em Demências	17
3.1.3 Reconhecimento de Emoções	19
3.1.4 Métricas de Avaliação da Classificação	21
3.2 Demências	22
3.3 Doença de Alzheimer	25
3.3.1 Alterações Cerebrais na Doença de Alzheimer	26
3.4 Terapias Atuais	29
3.4.1 Farmacológicas	29
3.4.2 Não Farmacológicas	31
3.4.3 Arteterapia	32
3.5 A Musicoterapia na Doença de Alzheimer	34
3.6 Emoções em Pacientes com Demência	35
4. Metodologia	38
4.1 Dados sobre a Coleta	38
4.1.1 Amostra de Participantes	39
4.1.2 Recrutamento dos Participantes	40
4.1.3 Instrumento de Coleta de Dados	40
4.1.4 Procedimentos para Coleta de Dados	40
4.2 Organização da Base de Dados	42
4.3 Classificação	43
4.4 Análise dos Métodos	44
4.5 Seleção de Atributos	44
5. Resultados e Discussões	45
5.1 Experiência da Coleta	45
5.2 Resultados dos Experimentos	45
6. Conclusão	54
6.1 Conclusões Gerais	54
6.2 Dificuldades Apresentadas	54
6.3 Contribuições e Trabalhos Futuros	55
Referências	57

LISTA DE FIGURAS

Figura 1 – Diagrama das Etapas da Metodologia	38
Figura 2 – Protocolo para Coleta de Dados	39
Figura 3 – Equipamentos utilizados para registro dos dados (Módulo de EEG)	41
Figura 4 – Equipamento utilizado para registro dos dados (Câmara Fotográfica)	41
Figura 5 – Etapas do procedimento de coleta de dados	42
Figura 6 – Exemplos de imagens geradas a partir dos sinais de (a) EEG e (b) voz	43
Figura 7 – Diagrama de caixa da acurácia do Classificador Random Forest	49
Figura 8 – Diagrama de caixa da sensibilidade do Classificador Random Forest	50
Figura 9 – Diagrama de caixa da especificidade do Classificador Random Forest	50
Figura 10 – Diagrama de caixa do kappa do Classificador Random Forest	51
Figura 11 – Diagrama de caixa da AUC-ROC do Classificador Random Forest	51

LISTA DE TABELAS

Tabela 1 – Resultado da validação cruzada para os métodos de classificação Bayes Net, Naive Bayes, Árvore de Decisão J48, Random Tree e Random Forest (100, 200, 300, 400 e 450 árvores), sem Seleção de Atributos	46
Tabela 2 – Valores de média, o desvio padrão das métricas de acurácia, kappa, sensibilidade, especificidade e área sob a curva ROC do seletor de atributos AG para os métodos de classificação Bayes Net, Naive Bayes, Árvore de Decisão J48, Random Tree e Random Forest (100, 200, 300, 400 e 450 árvores)	47
Tabela 3 – Valores de média, o desvio padrão das métricas de acurácia, kappa, sensibilidade, especificidade e área sob a curva ROC do seletor de atributos PSO para os métodos de classificação Bayes Net, Naive Bayes, Árvore de Decisão J48, Random Tree e Random Forest (100, 200, 300, 400 e 450 árvores)	48
Tabela 4 – Resultados para as bases de teste de todos os atributos para o método de classificação Random Forest de 200 árvores, do seletor de atributos AG para o método de classificação Random Forest de 100 árvores, do seletor de atributos PSO para o método de classificação Random Forest de 300 árvores	52
Tabela 5 – Matriz de confusão da classificação com todos os atributos	52
Tabela 6 – Matriz de confusão da classificação com atributos selecionados AG	53
Tabela 7 – Matriz de confusão da classificação com atributos selecionados PSO	53

CAPÍTULO 1

1. INTRODUÇÃO

O Brasil tem passado por mudanças demográficas significativas, por causa de diversos fatores, entre eles: a queda na taxa de natalidade, o aumento da expectativa de vida, e o avanço nos graus de urbanização e desenvolvimento econômico e humano. Essas mudanças demográficas indicam um futuro onde o Brasil terá uma população cada vez mais velha, trazendo desafios e oportunidades para o desenvolvimento socioeconômico do País. (Nitrini et al., 2005a,b; Aprahamian et al., 2009). Nos últimos 20 anos, houve um crescimento significativo na população idosa no Brasil, com um aumento próximo de 17,2%. Esse crescimento foi um dos fatores que contribuíram para o aumento geral da população brasileira na primeira década do século XXI. Segundo o IBGE (2011), esse aumento populacional ocorreu principalmente da população adulta e em especial, na população idosa. Esse fato representa as mudanças demográficas significativas no país, impulsionadas pela maior expectativa de vida e pela redução das taxas de fecundidade, resultando em uma população idosa.

O envelhecimento da população no Brasil é resultado de melhorias na qualidade de vida, entre elas: o avanço na medicina e o acesso amplo à saúde. Mesmo que o aumento da população idosa seja uma conquista, também é um desafio, pois traz consigo condições típicas dessa faixa etária, como a instabilidade postural, o que aumenta o risco de desequilíbrio e quedas. De acordo com Pinho (2014), essas situações são comuns em idosos e representam um problema de saúde pública, já que as quedas podem resultar em lesões graves, perda de autonomia, e aumento da mortalidade. Esses desafios destacam a importância de métodos de prevenção, como programas de atividade física focado no fortalecimento muscular e na autonomia dos idosos.

O envelhecimento é acompanhado por alterações fisiológicas que afetam de maneira significativa a qualidade de vida dos idosos. Entre essas mudanças, podemos destacar a diminuição da força muscular, as alterações na massa óssea, o déficit de equilíbrio, o aumento do balanço corporal, o declínio dos reflexos, a redução do controle postural, da coordenação motora, da flexibilidade, e do funcionamento do sistema vestibular (Siqueira, 2011). Essas mudanças são próprias do processo de senescência, que pertence ao envelhecimento natural do organismo. Essas alterações contribuem no risco de quedas e também outros riscos à saúde.

Com o envelhecimento da população brasileira, também há um aumento na prevalência de doenças relacionadas ao envelhecimento, como osteoporose, hipertensão e demências. Dentre essas, as demências são em especial desafiadoras por causa de seu impacto na qualidade de vida dos pacientes e de suas famílias (Nitrini et al., 2005a,b; Aprahamian et al., 2009). A doença de Alzheimer é a forma mais comum de demência e representa um desafio significativo para a saúde pública. Diversos fatores de risco

contribuem para o desenvolvimento dessa doença, incluindo fatores genéticos, sociodemográficos e de saúde (Nitrini et al., 2005a,b; Aprahamian et al., 2009).

A musicoterapia tem se mostrado uma ferramenta importante para desacelerar o progresso da doença de Alzheimer e outros déficits cognitivos, principalmente em estágios leves. (Gallego e Garcia, 2017; de Souza et al., 2017; Fang et al., 2017; King et al., 2019). A percepção musical está associada a áreas do cérebro que não são diretamente afetadas pelos déficits de memória ligados à doença, permitindo que a música atue de forma terapêutica em indivíduos com Alzheimer. (Fang et al., 2017; King et al., 2019). Para que a musicoterapia tenha efeitos mais significativos é preciso que as músicas aplicadas sejam personalizadas de acordo com cada paciente, atendendo aos gêneros, estilos, ritmos e instrumentos musicais que o paciente mais se identifica. A personalização exige tempo e dedicação dos profissionais de musicoterapia para entender e adaptar as intervenções, às necessidades individuais de cada paciente. Além da escuta dos estímulos musicais, a musicoterapia também envolve o estímulo que está ligado ao ato de tocar os instrumentos musicais. No entanto, o processo de aprendizagem já comprometido pela Doença de Alzheimer e por outros déficits cognitivos, torna a educação musical um desafio dentro da prática da musicoterapia.

Distribuindo eletrodos de superfície sobre o escalpo, é possível captar sinais eletroencefalográficos (EEG) de forma não invasiva, permitindo a monitoração da atividade cerebral em áreas específicas do córtex durante tarefas específicas. As Interfaces Cérebro-Máquina (BCI) são destacadas como ferramentas que não apenas avaliam a atividade cerebral, mas também possibilitam o controle de tecnologias assistivas, como cadeiras de rodas e neuropróteses, além de dispositivos de comunicação e entretenimento, incluindo a composição musical e jogos digitais. (Novak et al., 2018; Carlson e Millan, 2013). Além disso, também é possível descobrir e classificar emoções por meio da análise de sinais EEG, combinando BCI com técnicas de aprendizado de máquina. Estudos recentes, como os de Atkinson e Campos (2016), Zheng e Lu (2015), Song et al. (2018), Mohammadi et al. (2017), Torres et al. (2020), Li et al. (2020), e Subasi et al. (2021), são citados, destacando a importância e a eficácia dessa combinação na classificação emocional, ampliando o potencial das BCI no campo da computação afetiva e outras aplicações.

A Computação Afetiva é realmente um campo interdisciplinar fascinante que tem ganhado muita atenção nos últimos anos. Ao integrar inteligência artificial, processamento de linguagem natural e ciências cognitivas, entre outras disciplinas, esse campo busca criar sistemas que possam reconhecer, interpretar e até mesmo simular emoções humanas. Com o aumento do conteúdo multimídia online, como vídeos em plataformas como YouTube e redes sociais, a necessidade de analisar esses dados para entender emoções e opiniões se tornou essencial. Essa análise exige métodos sofisticados que possam lidar com a diversidade e a complexidade dos dados, como a análise de sentimentos em texto, detecção de emoções em expressões faciais e entonação de voz em vídeos, entre outros. Pesquisas recentes, como as de Poria et al. (2017) e Wu et al. (2016),

destacam o progresso no desenvolvimento dessas tecnologias, permitindo aplicações que vão desde a educação, onde sistemas podem adaptar o conteúdo com base no estado emocional dos alunos, até o design e artes visuais, onde a compreensão das emoções pode enriquecer a experiência do usuário.

Assim, emerge a seguinte pergunta de pesquisa: como as técnicas da Computação Afetiva para reconhecimento de emoções e as interfaces cérebro-máquina podem contribuir para construir soluções que possam auxiliar terapeutas, em especial musicoterapeutas e ludoterapeutas no geral, no contexto do tratamento de demências em estágio inicial?

A hipótese desta pesquisa é que o reconhecimento das emoções por meio da análise de sinais eletroencefalográficos pode contribuir para a construção de interfaces musicais humano-máquina que permitam auxiliar musicoterapeutas na determinação de gêneros musicais, estilos e ritmos que possam ser utilizados em processos de educação musical ou mesmo no apoio à composição de canções, no contexto do tratamento da doença de Alzheimer e do déficit cognitivo leve.

CAPÍTULO 2

2. OBJETIVOS

Este projeto tem como objetivo desenvolver uma interface musical cérebro-máquina para reconhecimento de emoções por meio de sinais eletroencefalográficos e de voz, para apoio à seleção de gêneros musicais, estilos e ritmos a serem utilizados no contexto da musicoterapia voltada ao tratamento da doença de Alzheimer, do déficit cognitivo leve e de demências em geral.

Este projeto tem os seguintes objetivos específicos ou metas:

1. Construir bases de dados de emoções a partir do registro de sinais de EEG, de voz e dados sociodemográficos, de pessoas com idade acima de 60 anos, saudáveis, com déficit cognitivo leve ou portadoras da doença de Alzheimer, aptas a participar de sessões de musicoterapia;
2. Construir uma arquitetura neural profunda para reconhecimento de emoções em sinais de EEG, voz e Dados sociodemográficos.
3. Validação dos resultados junto a pacientes idosos com e sem diagnóstico de demência.

2.1 ORGANIZAÇÃO DO TRABALHO

Esse trabalho está organizado em seis capítulos. No primeiro capítulo, encontra-se a Introdução, onde é feita uma contextualização do tema. No segundo capítulo encontram-se os objetivos propostos, são eles: geral e específicos. No terceiro capítulo, há o referencial teórico onde são apresentados conceitos fundamentais que norteiam o estudo. No quarto capítulo descreve a metodologia, onde vão ser apresentados a coleta de dados em conjunto com a descrição das etapas dos métodos de Extração e Seleção de Atributos com os Algoritmos Genéticos e Otimização por Enxame de Partículas, englobando desde a divisão dos conjuntos em Treinamento de Teste e Balanceamento até a etapa de classificação dos classificadores utilizados. No quinto capítulo, são apresentados os resultados dos experimentos e as discussões desses resultados. Por fim, no sexto capítulo é a conclusão, onde se divide em conclusões gerais, as dificuldades apresentadas, as contribuições e trabalhos futuros. Por último, apresentam-se as referências bibliográficas utilizadas na elaboração deste trabalho.

CAPÍTULO 3

3. REFERENCIAL TEÓRICO

Neste capítulo, serão apresentados os conceitos teóricos fundamentais que servem de base para o desenvolvimento deste trabalho. Esses conceitos oferecem uma base necessária para compreender as abordagens e técnicas utilizadas ao longo do estudo.

3.1 INTELIGÊNCIA ARTIFICIAL

O termo "artificial" remete a algo que não é natural, feito para imitar a natureza, produzido de forma artística ou industrial (MICHAELIS, 2018a). Já a "inteligência" não possui uma única definição, mas está associada ao entendimento, raciocínio, interpretação e à utilização do conhecimento adquirido para resolver situações e problemas (MICHAELIS, 2018b). Com a combinação desses conceitos, podemos entender a Inteligência Artificial (IA) como a criação de máquinas capazes de aprender e tomar decisões, utilizando algoritmos complexos que permitem a especulação e a interação com base nos dados gerados.

De fato, é um desafio definir a Inteligência Artificial (IA), por ser uma temática de conceito amplo e ao mesmo tempo complexo, mas que tem evoluído de forma significativa. Ainda assim, ao longo do tempo a IA seguiu quatro linhas de pensamento: I. Sistemas que pesam como seres humanos: Esta abordagem, citada por Haugeland (1985), foca na criação de máquinas que possam replicar o pensamento humano de maneira completa e literal, sugerindo uma tentativa de imitar a mente humana. II. Sistemas que atuam como seres humanos: Segundo Kurzweil (1990), essa linha de pensamento se concentra na criação de máquinas capazes de realizar tarefas que, quando executadas por humanos, exigem inteligência, enfatizando o comportamento humano em ações práticas. III. Sistemas que pensam racionalmente: Charniak e McDermott (1985) destacam o estudo das faculdades mentais humanas através de modelos computacionais, colocando a ênfase na racionalidade e no raciocínio lógico. IV. Sistemas que atuam racionalmente: Poole et al. (1998) descrevem a IA como o estudo do design de agentes inteligentes, que são sistemas capazes de agir de maneira racional e eficaz, considerando as melhores ações para atingir seus objetivos.

Essas quatro abordagens mostram a diversidade de pensamentos e métodos aplicados ao desenvolvimento de sistemas inteligentes, refletindo tanto o comportamento humano quanto a racionalidade em contextos computacionais.

As linhas de pensamento I e III focam nos processos internos da Inteligência Artificial (pensamento e raciocínio), enquanto as linhas de pensamento II e IV se concentram no comportamento externo (ação e interação). Já as linhas de pensamento I e II medem o sucesso da Inteligência Artificial comparando-a com o desempenho humano, enquanto as linhas III e IV estabelecem um padrão ideal de racionalidade como

referência. Um sistema é racional se “faz tudo certo”, com os dados que tem (RUSSELL; NORVIG, 2004).

3.1.1 HISTÓRICO

Na década de 1950, Alan Turing propôs um teste chamado “*Teste de Turing*”, como uma forma de avaliar a inteligência de uma máquina com base na sua capacidade de imitar a inteligência humana. Então, se um observador não consegue diferenciar as respostas de um ser humano e de uma máquina (computador) tendo como base a comunicação textual, o computador é considerado inteligente. Na versão do “Behaviorismo”, as máquinas seriam ou não inteligentes se passassem ou não no *Teste de Turing*: um observador numa sala se comunica através de teletipo com dois interlocutores em salas separadas: um humano e um computador, por um período específico. Então, pode-se dizer que qualquer coisa é inteligente se for apto a passar no teste de Turing. Para ser bem sucedido, as máquinas precisam de quatro capacidades: (A) Processamento de linguagem natural, a máquina deve ser capaz de entender e gerar linguagem de maneira que pareça natural e convincente; (B) Conhecimento, a máquina precisa ter uma base de dados para armazenar e recuperar informações relevantes para a conversação; (C) Raciocínio automatizado, a máquina deve utilizar as informações armazenadas para responder a perguntas e fazer inferências lógicas; e (D) Aprendizado de máquina, a capacidade de adaptar-se a novas situações e aprender com novas informações é essencial para melhorar o desempenho e detectar padrões. Essas capacidades são centrais para o desenvolvimento de sistemas de IA avançados que podem interagir de forma eficaz com os humanos e realizar tarefas complexas. (RUSSELL; NORVIG, 2009).

O período de 1952 a 1969 foi um momento importante para o desenvolvimento da inteligência artificial, apesar de poucos progressos. Durante esse tempo, pessoas influentes como John McCarthy, Hyman Minsky, Claude Shannon e Nathaniel Rochester foram fundamentais para a formação do campo. Em 1956, eles organizaram o famoso seminário de dois meses em Dartmouth, considerado o marco inicial da inteligência artificial como uma disciplina acadêmica. Este evento contou com a presença de outros notáveis da área: Trenchard More (Princeton), Arthur Samuel (IBM), Allen Newell e Herbert Simon (CMU), Ray Solomonoff e Oliver Selfridge do (MIT). Os destaques do Seminário foram: Allen Newell e Herbert Simon, apresentaram o programa de raciocínio *Logic Theorist* (LT), considerado por muitos como o primeiro programa de IA. Ainda que o seminário não tenha trazido muitas novidades, ele foi fundamental para a introdução e conexão dos principais pesquisadores da área. Russell e Norvig (2004) observam que as duas décadas seguintes foram dominadas por essas pessoas e por seus alunos e colegas das instituições MIT, CMU, Stanford e da IBM, moldando de forma significativa o desenvolvimento da Inteligência Artificial (RUSSELL; NORVIG, 2004).

No ano de 1969, foi desenvolvido pela Universidade de Stanford o programa DENDRAL, uma inovação significativa na inteligência artificial aplicada à química. Esse programa foi projetado para determinar estruturas moleculares orgânicas a partir da

análise de dados de espectrometria de massa. O desenvolvimento deste programa contou com a ajuda de pessoas importantes como, Edward Feigenbaum (um antigo aluno de Herbert Simon), Bruce Buchanan (um filósofo que se tornou cientista da computação) e Joshua Lederberg (um geneticista premiado com um prêmio Nobel) constituíram equipe para resolver o problema e o DENDRAL foi capaz de tomar decisões de forma automática, identificando estruturas moleculares a partir de dados complexos, utilizando um grande número de regras específicas. O DENDRAL teve sua importância para a construção de sistemas inteligentes, porque representou o primeiro sistema bem-sucedido de conhecimento intensivo: sua habilidade derivava de um grande número de regras de propósito específico (RUSSELL; NORVIG, 2004).

O desenvolvimento e implementação de sistemas especialistas nos anos 1980 marcaram um período significativo na história da inteligência artificial aplicada comercialmente. Um dos primeiros sistemas especialistas comerciais bem-sucedidos foi o R1, desenvolvido pela *Digital Equipment Corporation* (DEC). O programa contribuiu para configurar pedidos de novos sistemas de computador. Em 1986, ele já estava contribuindo com cerca de 40 milhões de dólares por ano para a empresa. Em 1988, o grupo de IA da DEC já possuía 40 sistemas especialistas entregues, com outros sendo produzidos (CHARNIAK; MCDERMOTT, 1985). A Du Pont tinha 100 sistemas especialistas em uso e outros 500 em desenvolvimento, resultando em economias de aproximadamente 10 milhões de dólares por ano. Quase todos os grandes conglomerados dos Estados Unidos possuíam seus próprios grupos de IA e estavam usando ou investigando sistemas especialistas para otimizar operações e reduzir custos.

Em 1981, o anúncio do projeto *Fifth Generation* pelo Japão marcou um ponto importante na história da inteligência artificial e da computação. O projeto tinha o objetivo de desenvolver computadores inteligentes utilizando a linguagem de programação Prolog. Este plano de 10 anos foi concebido para impulsionar a tecnologia de computação e IA, posicionando o Japão na vanguarda da inovação tecnológica. Para manter a competitividade nacional e responder ao desafio tecnológico japonês, os Estados Unidos constituíram a *Microelectronics and Computer Technology Corporation* (MCC). Este consórcio de pesquisa foi projetado para assegurar que os Estados Unidos permanecessem na liderança da tecnologia de computação. Em ambos os casos, a IA fazia parte de um amplo esforço, incluindo o projeto de chips e a pesquisa da interface humana.

Nos últimos anos, a pesquisa em inteligência artificial (IA) passou por uma transformação significativa tanto em termos de conteúdo quanto de metodologia. Este período foi caracterizado por mudanças importantes na abordagem dos cientistas e engenheiros em relação ao desenvolvimento e aplicação da IA. Russell e Norvig (2004) destacam várias dessas mudanças: Em vez de propor teorias inteiramente novas, é mais comum os pesquisadores basearem seus trabalhos nas teorias existentes. Isso cria uma base sólida de conhecimento acumulado que pode ser expandida e refinada. As afirmações e hipóteses são agora fundamentadas em teoremas rigorosos ou evidências experimentais robustas. Essa abordagem científica rigorosa melhora a credibilidade e a

validade dos trabalhos de IA. Há um foco crescente na relevância das aplicações reais, em oposição aos exemplos de brinquedos ou casos hipotéticos. Isso significa que os desenvolvimentos em IA estão sendo testados e implementados em cenários do mundo real, demonstrando seu valor prático e impacto.

3.1.2 TIPOS DE APLICAÇÃO EM DEMÊNCIAS

A Inteligência Artificial está sendo aplicada em várias áreas da saúde, incluindo o diagnóstico de doenças como as demências. Na Universidade de Cambridge (Inglaterra), um projeto inovador está investigando o uso da IA para identificar de modo precoce as demências através da análise de imagens obtidas por tomografias do cérebro. (CORREIA, 2021)

O uso da inteligência artificial no diagnóstico precoce de demências pode trazer benefícios significativos para os pacientes e as suas famílias. Com a descoberta antecipada da doença, é possível adotar medidas terapêuticas que podem atrasar o seu desenvolvimento. Isso oferece aos pacientes e seus familiares mais informações sobre o provável avanço da demência, ajudando-os a planejar suas vidas de maneira mais eficaz e esclarecida. (CORREIA, 2021)

Segundo Correia (2021), uma equipe liderada pela professora Zoe Kourtzi da Universidade de Cambridge e do The Alan Turing Institute desenvolveu ferramentas de aprendizado de máquina capazes de identificar a demência em estágios iniciais. Este projeto utiliza imagens cerebrais de pacientes que desenvolveram Alzheimer para treinar o algoritmo de aprendizado de máquina, permitindo que ele identifique mudanças estruturais no cérebro. Quando combinado com os resultados de testes de memória padrão, o algoritmo foi capaz de oferecer uma pontuação de prognóstico – ou seja, a possibilidade do indivíduo ter a doença de Alzheimer.

A aplicação da inteligência artificial no diagnóstico da doença de Alzheimer representa um avanço significativo na área da saúde. A complexidade da doença e a necessidade de um diagnóstico precoce tornam a IA uma ferramenta promissora. A doença de Alzheimer é, de fato, uma das doenças neurológicas de maior prevalência e o impacto significativo na vida, afetando milhões de pessoas e suas famílias (Relatório Mundial de Alzheimer, 2021). O caráter progressivo e a falta de uma cura eficaz tornam o diagnóstico precoce um fator crítico para permitir intervenções terapêuticas que possam melhorar a qualidade de vida dos pacientes.

O diagnóstico do Alzheimer é tradicionalmente realizado através de uma combinação de avaliação clínica e análise de exames de imagem por especialistas em neurologia ((RUSSELL; NORVIG, 2013). Porém, quando as características presentes nas imagens não são claras o suficiente para diferenciação entre pacientes saudáveis e aqueles com Alzheimer, técnicas de Inteligência Computacional têm sido desenvolvidas para auxiliar os especialistas a avaliar melhor o estado de saúde dos pacientes (Azevedo, 2019).

A pesquisa em visão computacional tem avançado de forma significativa no uso de sistemas de diagnóstico auxiliado por computador (CAD) para o diagnóstico precoce da Doença de Alzheimer, utilizando ressonância magnética estrutural (SMRI). Essas estratégias de CAD melhoram a capacidade de diagnóstico ao combinar diferentes modalidades de imagens em um único modelo de aprendizado. A ImageTens, uma modalidade que fornece informações complementares às imagens de ressonância magnética anatômica, destaca-se como uma abordagem promissora na detecção precoce da doença de Alzheimer. Porém, a integração das informações obtidas do DTI (Diffusion Tensor Imaging) enfrenta desafios técnicos substanciais (Ahmed et al., 2016).

A descoberta precoce da doença de Alzheimer é fundamental, pois, apesar de ainda não existir uma cura conhecida, identificar a doença em seus estágios iniciais permite a possibilidade de adotar tratamentos que possam desacelerar os impactos causados por essa condição e minimizar os sintomas, melhorando a qualidade de vida do paciente (Azevedo, 2019).

O diagnóstico precoce da Doença de Alzheimer é essencial para a implementação de tratamentos adequados e para melhorar a qualidade de vida dos pacientes. A confirmação da doença geralmente requer a identificação de biomarcadores específicos, conforme critérios estabelecidos pelo Instituto Nacional do Envelhecimento (NIA) e pela Associação de Alzheimer (AA). Esses critérios incluem a detecção de pelo menos um biomarcador anormal, que pode ser identificado por meio de: (A) Ressonância Magnética (MRI): Usada para visualizar alterações estruturais no cérebro; (B) Tomografia por Emissão de Pósitrons (PET): Ajuda a identificar depósitos de beta-amiloide e outras características patológicas; (C) Fluido Cerebrospinal (CSF): Analisado para medir níveis de proteínas associadas à Doença de Alzheimer, como beta-amiloide e tau (Liu et al., 2018).

Esses métodos de diagnóstico são fundamentais para confirmar a presença da Doença de Alzheimer e para diferenciar a doença de outras condições que podem apresentar sintomas semelhantes.

Os biomarcadores são essenciais para a avaliação e confirmação da Doença de Alzheimer, oferecendo insights sobre a fisiopatologia da doença. As técnicas mais comuns incluem: (A) Ressonância Magnética (MRI): Detecta mudanças estruturais iniciais no cérebro, particularmente no lobo temporal medial, incluindo áreas como o córtex entorrinal e o hipocampo, que são frequentemente afetadas nas fases iniciais da Doença de Alzheimer; (B) PET com Fluorodesoxiglicose (FDG): Mede o metabolismo da glicose no cérebro. A diminuição da captação de FDG pode indicar áreas de metabolismo reduzido, associadas à degeneração neuronal; (C) PET com Amiloide: Identifica o acúmulo de beta-amiloide no tecido cerebral. O acúmulo de amiloide é uma característica distintiva da Doença de Alzheimer e pode ajudar a confirmar o diagnóstico; (D) Fluido Cerebrospinal (CSF): A análise do CSF pode refletir alterações nos níveis de beta-amiloide ($A\beta$) e proteínas tau, que estão associadas à patologia da Doença de Alzheimer (Westman et al., 2012).

Esses biomarcadores são utilizados para melhorar a precisão do diagnóstico e para monitorar a progressão da doença, além de possibilitar uma abordagem mais personalizada para o tratamento e manejo da Doença de Alzheimer.

A aplicação da Inteligência Artificial no diagnóstico de doenças neurodegenerativas tem apresentado resultados satisfatórios, especialmente em modalidades comuns, como ressonância magnética, SPECT, estado eletroencefalográfico (EEG), caligrafia e fala na Doença de Parkinson (Silva Souza et al., 2022). O modelo utilizado alcançou uma precisão superior a 80%, destacando o potencial de ferramentas de *Computer-Aided Design* (CAD) no diagnóstico não apenas da Doença de Parkinson, mas também de outras doenças neurodegenerativas. Portanto, a combinação dessas tecnologias avançadas no campo da saúde pode contribuir para avanços significativos, na descoberta precoce e no diagnóstico preciso da doença de Alzheimer, proporcionando tratamentos mais eficazes e melhorias na qualidade de vida dos pacientes (Silva Souza et al., 2022).

De acordo com estudos anteriores (Silva Souza et al., 2022), uma variedade de métodos de análise de imagens baseados em IA tem sido utilizada para auxiliar no diagnóstico de patologias, esses métodos oferecem benefícios significativos na precisão e confiabilidade dos diagnósticos.

O uso da inteligência artificial em demências está em constante evolução, e a pesquisa continua a explorar novas maneiras de aproveitar essa tecnologia para melhorar o diagnóstico, tratamento e qualidade de vida dos indivíduos afetados.

3.1.3 RECONHECIMENTO DE EMOÇÕES

Segundo Reeve (2006), as emoções são essenciais para a socialização, e as expressões faciais são um meio crucial para comunicar essas emoções. Em seguida, Darwin (2004), diz que as emoções e expressões faciais têm um papel comunicativo significativo em várias espécies animais, ajudando na adaptação e sobrevivência. Andrade et al. (2013), que a capacidade de entender e lidar com as emoções próprias e alheias está relacionada à melhoria da qualidade de vida e das interações sociais. Para Izard (2002), as emoções são usadas de maneira adaptativa para regular o comportamento, influenciando diretamente o funcionamento social e individual. Essas ideias enfatizam como a compreensão e a expressão das emoções são fundamentais tanto para a comunicação eficaz quanto para o bem-estar e a adaptação dos indivíduos em contextos sociais e pessoais.

Picard (1997) menciona que o debate sobre a universalidade das emoções tem suas raízes no século XIX, com Charles Darwin argumentando que as expressões emocionais são parte da continuidade evolutiva entre espécies. Darwin sugeriu que as emoções e suas expressões são universais e têm uma base biológica comum entre os seres humanos e outros animais.

Jaques e Viccari (2005) destacam que as emoções podem ser demonstradas de várias formas e que existem vários métodos para captar e reconhecer. Os principais modos de reconhecimento de emoções incluem: I. A Voz (a tonalidade, ritmo e intensidade da voz podem fornecer pistas sobre o estado emocional de uma pessoa), II. As ações do usuário (comportamentos e ações, como expressões faciais, gestos e posturas, também são indicativos das emoções que uma pessoa está sentindo) e III. Os sinais fisiológicos (aspectos como frequência cardíaca, respiração e condutância da pele são sinais fisiológicos que podem indicar emoções). Esses métodos oferecem uma visão abrangente sobre como as emoções podem ser expressas e interpretadas, desde o comportamento observável até os indicadores fisiológicos mais sutis.

Fasel e Luetin (2003) destacam uma diferença fundamental entre o reconhecimento de emoções e o reconhecimento das expressões faciais. No reconhecimento de expressões faciais, a análise foca nas características e ações faciais por meio de imagens. Este método é eficaz para identificar expressões particulares, como um sorriso ou franzir as sobrancelhas, associadas a estados emocionais específicos. No caso de reconhecimento de emoções, é mais complexo, pois envolve uma interpretação mais abrangente, que vai além da expressão facial. Este processo tem a consideração de vários fatores além da expressão facial, como a variação da voz, a direção do olhar, gestos, e a postura. Apenas observar um sorriso pode não ser suficiente para determinar se é uma expressão de alegria ou uma pose. A análise mais completa leva em conta múltiplos sinais para inferir corretamente a emoção subjacente. Ekman (1999) acrescenta que, apesar de uma pessoa poder tentar mascarar suas emoções ou expressar uma emoção que não está realmente sentindo, certos músculos faciais só se movem de forma específica quando a emoção verdadeira é experimentada. Isso sugere que existem indicadores faciais autênticos que são difíceis de falsificar e que podem ajudar a identificar emoções genuínas.

Para que se possa estudar as emoções, é necessário também estudar o cérebro humano e como ele se comporta. Uma das maneiras de alcançar respostas é utilizando o EEG (Eletroencefalograma), que é uma ferramenta valiosa para estudar o cérebro humano, medindo a atividade elétrica produzida pelos neurônios. SANEI e CHAMBERS (2007) destacam que a análise dos sinais gerados pelo EEG pode ajudar no diagnóstico de várias disfunções neurológicas e anomalias corporais, como epilepsia, distúrbios do sono, e outras condições relacionadas ao funcionamento cerebral. O EEG é útil porque oferece uma visão direta da atividade elétrica cerebral em tempo real, permitindo aos pesquisadores e clínicos identificar padrões que podem estar associados a diferentes estados emocionais, cognitivos e neurológicos.

O Eletroencefalograma (EEG) é amplamente utilizado devido à sua segurança e ausência de contraindicações, sendo adequado para pessoas de todas as idades, além de ser um procedimento não invasivo (Sanei; Chambers, 2007). No entanto, o monitoramento manual das ondas cerebrais geradas ao longo do tempo é impraticável devido ao volume massivo de dados que o EEG produz. Essa limitação torna difícil a

inspeção visual contínua e a identificação precisa de respostas a certos estímulos, destacando a necessidade de métodos automatizados e algoritmos para processar e interpretar esses dados de forma eficiente.

Para enfrentar os desafios associados ao grande volume de dados gerados por EEG, os algoritmos de aprendizado de máquina (*machine learning*) são cruciais. Esses algoritmos podem analisar as informações ricas e complexas dos sinais de EEG (HELM et al., 2020). Ao detectar padrões e classificar respostas a estímulos, esses algoritmos permitem a identificação de emoções básicas e outros estados neurológicos.

Machine learning, uma subcategoria da inteligência artificial, destaca-se pelo treinamento de algoritmos com base em grandes volumes de dados (HELM et al., 2020). Esse treinamento é essencial para descobrir e compreender padrões subjacentes (DAS; BEHERA, 2017). Além disso, existem diversas ferramentas e técnicas dentro do machine learning, escolhidas com base nos objetivos da análise e na origem dos dados (QIU et al., 2016).

3.1.4 MÉTRICAS DE AVALIAÇÃO DA CLASSIFICAÇÃO

Existem diversas métricas de avaliação que são utilizadas para medir o desempenho de modelos inteligência artificial para classificação, como a tarefa de classificação de emoções. Algumas das métricas mais comuns são: Acurácia, Sensibilidade, Especificidade, Índice Kappa e Área sob a Curva ROC (AUC-ROC). Estas métricas são fundamentais para avaliar o desempenho geral dos classificadores em diferentes contextos e garantir que os modelos não apenas acertem previsões, mas também sejam consistentes.

A Acurácia é uma métrica usada para avaliar o desempenho de um modelo de classificação, representando a proporção previsões corretas (tanto verdadeiros positivos quanto verdadeiros negativos) em relação ao total de previsões realizadas. Ela é calculada conforme apresentada na Equação 1, onde **TP** é a quantidade de verdadeiros positivos, **TN** é a quantidade de verdadeiros negativos, **FP** é a quantidade de falsos positivos, **FN** é a quantidade de falsos negativos. Ainda que a Acurácia seja uma medida geral de desempenho útil, mas pode ser enganosa em casos de desbalanceamento de classes.

$$Acurácia = \frac{TP + TN}{TN + TP + FP + FN} \quad (1)$$

A Sensibilidade é uma métrica que mede a capacidade de um teste em identificar de forma correta os resultados positivos. É a probabilidade de que um teste identifique um verdadeiro positivo, conforme demonstrado na Equação 2, onde **TP** é a quantidade de verdadeiros positivos, **FN** é a quantidade de falsos negativos. A sensibilidade é fundamental em aplicações onde o custo de um falso negativo é alto, como em diagnósticos médicos.

A Especificidade é uma métrica que mede a capacidade de um teste em identificar de forma correta os resultados negativos. É a probabilidade de que um teste forneça um verdadeiro negativo, conforme apresentado na Equação 3, onde **TN** é a quantidade de verdadeiros negativos, **FP** é a quantidade de falsos positivos. A especificidade é fundamental em aplicações onde o custo de um falso positivo é alto, como em triagens que podem levar a tratamentos desnecessários ou preocupações infundadas.

$$\text{Sensibilidade} = \frac{TP}{TP + FN} \quad (2)$$

$$\text{Especificidade} = \frac{TN}{TN + FP} \quad (3)$$

Área sob curva ROC (AUC-ROC) é uma métrica que avalia o desempenho de um modelo de classificação binária. Onde as curvas descrevem a capacidade discriminativa de um teste diagnóstico, permitindo quantificar quanto um teste é exato, como demonstrativo na Equação 4. A área sob a curva ROC é o único valor que resume o desempenho global do classificador. Um valor de AUC próximo a 1 indica um classificador excelente, enquanto um valor próximo a 0.5 indica um classificador aleatório.

$$AUC = \int TP d(FP) \quad (4)$$

O Índice Kappa é uma métrica utilizada para medir o grau de concordância ou reprodutibilidade entre dois conjuntos de dados, levando em consideração a possibilidade de concordância ao caso, conforme apresentado na Equação 5, onde **Po** é a proporção de concordância observada e **Pe** é a proporção de concordância esperada ao acaso. O Kappa em particular é útil em situações onde as categorias são desbalanceadas.

$$K = \frac{Po - Pe}{1 - Pe} = 1 - \frac{1 - Po}{1 - Pe} \quad (5)$$

As métricas de avaliação em modelos de classificação desempenham um papel fundamental no desenvolvimento e na comparação de modelos de classificação. Ao entender as diferentes métricas e suas implicações, você poderá escolher as métricas mais adequadas para avaliar o desempenho do seu modelo e tomar decisões mais informadas sobre a sua aplicação.

3.2 DEMÊNCIAS

Segundo Barclay (1993), a demência é uma síndrome clínica marcada por uma deterioração significativa das funções corticais superiores, incluindo memória,

pensamento, orientação, compreensão, cálculo, capacidade de aprendizagem, linguagem e julgamento. Essa deterioração reflete uma perda de habilidades antes adquiridas pelo indivíduo, embora a consciência do paciente permaneça inteira. A gravidade da demência é tal que interfere substancialmente nas atividades sociais e ocupacionais do indivíduo. A demência pode afetar a qualidade de vida de forma abrangente, tornando essencial a detecção precoce e o manejo adequado para melhorar o prognóstico e o suporte ao paciente e à sua família.

A demência é uma condição complexa com diversas causas, que são divididas em primárias e secundárias. Cassel (1990) cita como causas primárias as doenças neurodegenerativas que afetam diretamente o cérebro, como: as doenças de Alzheimer, Pick, Huntington, Parkinson, paralisia supranuclear progressiva, degeneração espinocerebelar, calcificação idiopática dos núcleos da base, degeneração estriato-nigral, xantomatose cérebro-espinhosa, leucodistrofia metacromática. As causas secundárias, resultam de outras patologias ou condições, como: os acidentes vasculares cerebrais, traumatismos, condições intracranianas, distúrbios endócrinos e metabólicos, estados de deficiência de vitamina B12, vitamina B6 e ácido fólico, infecções, intoxicações e desordens psiquiátricas como esquizofrenia, mania e alcoolismo. A identificação correta da causa da demência é essencial para um tratamento e intervenções mais adequadas.

De acordo com a Organização Mundial da Saúde (2019), a demência é uma das principais causas de incapacidade em populações mais idosas, e com o aumento da longevidade há um crescimento proporcional no número de casos dessa síndrome, o que exige um planejamento adequado para cuidados médicos e sociais, para lidar com o impacto crescente da demência na sociedade. Além disso, a falta de conhecimento e compreensão sobre as características da demência pode levar ao preconceito e discriminação, dificultando o acesso aos serviços de saúde e apoio clínico.

A forma como a demência afeta cada indivíduo pode variar e não é apenas pelo dano cerebral resultante da doença. A influência da demência é moldada por uma combinação de fatores, como a personalidade e as características psicológicas do indivíduo, experiências de vida e o suporte social e a qualidade do ambiente em que o indivíduo vive (OMS, 2019).

A demência pode se manifestar de várias formas e diferentes intensidades. Os sintomas podem variar desde pequenas perdas de memória até dificuldades graves em áreas como comunicação e tomada de decisões, a ponto de comprometer a capacidade de realizar atividades diárias sem assistência. (OMS, 2019). Em geral, a demência está associada a uma deterioração cognitiva acompanhada de sintomas psicológicos (e.g. depressão, ansiedade, delírio, alucinações) e comportamentais (e.g. agitação, agressão, apatia). Esses sintomas podem variar significativamente em termos de gravidade e manifestação, dependendo do tipo de demência e das características individuais do paciente. A abordagem ao tratamento e ao manejo da demência deve considerar essa diversidade de sintomas e a forma como eles afetam a vida do indivíduo e de seus familiares (PRADO et al., 2019; OMS, 2019).

A progressão da demência é dividida em três fases, mas a experiência pode variar entre os indivíduos. É importante perceber que nem todas as pessoas com demência apresentarão todos os sintomas, nem na mesma altura (OMS, 2019). Na fase inicial da doença, os sintomas são sutis e podem ser confundidos com sinais normais do envelhecimento, o que pode subestimar os problemas. Um dos sintomas mais comuns é a perda de memória (dificuldades em aprender novas informações ou lembrar de detalhes recentes são comuns), que são associados ao próprio processo de envelhecimento. Nesta fase inicial podem ainda surgir dificuldades ao nível da orientação temporal e espacial (a pessoa pode confundir o dia da semana ou o mês, e pode se perder em lugares familiares), assim como problemas em tomar decisões.

Conforme a demência avança para a fase intermediária, os sintomas ficam mais visíveis e podem incluir: (A) Dificuldades de comunicação: Problemas em encontrar palavras ou manter uma conversa coerente. (B) Resolução de problemas: Dificuldades em tomar decisões ou lidar com tarefas complexas. (C) Reconhecimento: Dificuldade em reconhecer pessoas conhecidas. Nesta fase, também podem surgir: (A) Alterações de humor: Mudanças emocionais, como irritabilidade ou apatia. (B) Mudanças de comportamento: Pode haver desinibição, comportamento inadequado, ou deambulação persistente. (C) Dificuldades em atividades diárias: Problemas em realizar tarefas como tomar a medicação ou manter o arranjo pessoal. Na fase avançada, a deterioração se torna mais severa, caracterizada por: (A) Reconhecimento limitado: Grande dificuldade em reconhecer familiares ou amigos próximos. (B) Comportamento perturbador: A pessoa pode exibir comportamentos que são angustiantes para os outros. (C) Deterioração severa das funções mentais: A perda cognitiva é significativa, resultando em inatividade e dependência total. Essas mudanças refletem o avanço da demência e aumenta a necessidade de cuidados mais intensivos e de apoio contínuo para os pacientes e cuidadores (OMS, 2019).

O tratamento da demência depende da sua causa específica. A Doença de Alzheimer, sendo uma condição progressiva e atualmente incurável, têm em vista:

1. Tratamentos farmacológicos: Podem ajudar a estabilizar temporariamente e retardar o declínio cognitivo, principalmente em fases iniciais da demência. Há medicamentos que podem ser utilizados para o manejo de sintomas comportamentais e psicológicos, como agitação e depressão (Escher et al., 2019).
2. Tratamentos não-farmacológicos: São fundamentais na melhoria dos sintomas psicológicos e comportamentais. Essas abordagens incluem: (A) Intervenções psicossociais: Projetadas para promover o bem-estar físico, psicológico e social do paciente, bem como de seus familiares e cuidadores. (B) Estimulação cognitiva: Atividades que visam manter ou melhorar as capacidades mentais do paciente. (C) Modificações ambientais: Sugestões para adaptar o ambiente ao paciente, facilitando o desempenho diário e os cuidados. (D) Apoio ao cuidador: Formação, apoio constante e descanso são essenciais para melhorar a qualidade de vida dos cuidadores e, conseqüentemente, a do paciente.

Essas estratégias ajudam no controle dos sintomas e na qualidade de vida dos pacientes, como também na saúde e bem-estar dos cuidadores, proporcionando uma abordagem mais holística ao tratamento da demência (OMS, 2012).

3.3 DOENÇA DE ALZHEIMER

De acordo com Sereniki e Vital (2008), a doença de Alzheimer é um tipo de demência que afeta as pessoas idosas e é caracterizada pela degeneração progressiva do cérebro. A doença atinge aproximadamente 10% dos indivíduos com 65 anos de idade ou mais, e a taxa aumenta para aproximadamente 40% entre aqueles com 80 anos ou mais. A principal característica da doença de Alzheimer é a neurodegeneração, que leva a uma deficiência cognitiva progressiva e eventual incapacidade. A primeira evidência clínica notável é a perda na memória recente, que é seguida pela deterioração de outras funções cognitivas conforme a doença avança.

De acordo com Masumoto e colaboradores (2010), a doença de Alzheimer é uma condição incurável e sua causa ainda é desconhecida. O que se sabe é que a doença provoca lesões cerebrais, levando à morte de neurônios e resultando na perda progressiva da memória e outras funções cognitivas. Isso compromete a capacidade da pessoa de realizar tarefas do dia a dia, comprometendo a sua qualidade de vida.

Fridman e colaboradores (2004) apontam que entre 17 a 25 milhões de pessoas no mundo sofrem com a Doença de Alzheimer, representando entre 8% a 15% da população com mais de 65 anos. Estima-se que uma em cada 10 pessoas com mais de 80 anos poderá ser afetada pela doença no futuro. Aproximadamente 1 em cada 100 pessoas com 70 anos e 1 em cada 1000 pessoas com 60 anos pode ser afetada. Os autores destacam que a Doença de Alzheimer já é a terceira principal causa de morte nos países desenvolvidos, ficando atrás apenas do câncer e das doenças cardiovasculares.

A Doença de Alzheimer é uma condição neurodegenerativa grave. A Doença de Alzheimer é marcada pela perda progressiva da massa cinzenta do cérebro, que contém os corpos celulares dos neurônios. Esta perda resulta em deterioração cognitiva significativa. Entre as principais mudanças estão a perda gradativa da memória e outras funções cognitivas, que afetam a capacidade de pensar, lembrar e realizar tarefas diárias. Trata-se de uma condição neurológica degenerativa, progressiva e incurável. A progressão é lenta, com o comprometimento gradual e irreversível das funções cerebrais. (Fernandes & Andrade, 2017). Como observado por Caetano et al. (2017), a Doença de Alzheimer causa declínios irreversíveis no funcionamento do indivíduo. Essa doença se desenvolve lentamente e geralmente acompanha o indivíduo ao longo da vida, caracterizando-se como uma condição crônica e progressiva (Fernandes & Andrade, 2017). A doença está associada à destruição dos neurônios colinérgicos, que são importantes para a função cognitiva e a memória (Machado, Carvalho & Rocha Sobrinho, 2020).

A etiologia da Doença de Alzheimer não é totalmente definida. Segundo Spezzia (2018), a doença possui uma etiologia desconhecida, mas pode ser influenciada por diversos fatores como sexo, idade, doença cérebro vascular, traumas cerebrais e aspectos como ocupação profissional e grau de escolaridade. Rios Filho et al. (2017) destacam a incerteza em relação as causas da doença de Alzheimer. Entretanto, eles indicam que sua causa tenha relação com outros aspectos, como: (A) Fatores genéticos, certos genes podem aumentar o risco de desenvolver a doença; (B) Privação de sono, a falta de sono pode comprometer o funcionamento e o desempenho das sinapses, contribuindo para o desenvolvimento da doença. Monteiro (2018) apresenta uma perspectiva adicional e sugere que o Alzheimer pode estar ligado a uma "proteopatia". Essa hipótese envolve anomalias no envelhecimento de proteínas no cérebro.

O esquecimento é uma das principais características da Doença de Alzheimer e geralmente começa com lapsos de memória relacionados a atividades diárias, como relatado por Aragão et al. (2018) e Monteiro (2018). No estágio inicial, esses esquecimentos podem ser atribuídos ao envelhecimento normal, o que pode dificultar o diagnóstico precoce, como menciona Gimenes (2019). Com o avanço da doença, a memória se agrava ainda mais, e o indivíduo pode ter dificuldade em lembrar eventos recentes. No estágio final, a perda de autonomia é completa, com o paciente não conseguindo realizar tarefas básicas como falar, andar ou vestir-se, tornando-se totalmente dependente.

O esquecimento é o principal sintoma do Alzheimer, mas ele é apenas um dos muitos desafios enfrentados pelos pacientes. Segundo Vieira (2020), não demora para que a linguagem também seja afetada, tornando-se difícil inclusive dar os nomes aos objetos. Essa diminuição da habilidade de falar pode levar ao desenvolvimento de apraxia e agnosia nos pacientes. Além da afasia nesses casos, Cecato (2017) comenta sobre: (A) Comprometimento da linguagem, deterioração da capacidade de se expressar verbalmente; (B) Raciocínio abstrato, dificuldade em compreender conceitos abstratos e realizar tarefas que envolvem raciocínio complexo; e (C) Tomada de decisão, comprometimento da capacidade de tomar decisões lógicas e coerentes.

3.3.1 ALTERAÇÕES CEREBRAIS NA DOENÇA DE ALZHEIMER

Na Doença de Alzheimer, a degeneração cerebral destrói as células nervosas e compromete a eficácia dos neurotransmissores, os mensageiros químicos essenciais para a comunicação entre as células nervosas. Um exemplo notável é a acetilcolina, que é fundamental para processos cognitivos como memória, aprendizado e concentração. De acordo com o Manual MSD (2023), na Doença de Alzheimer, os níveis de acetilcolina são significativamente baixos, o que contribui diretamente para os déficits cognitivos característicos da doença.

A Doença de Alzheimer causa várias anomalias no desenvolvimento do tecido cerebral, que estão associadas à degeneração das células nervosas e ao declínio cognitivo. Essas anomalias incluem:

1. Depósitos de beta-amiloide: A beta-amiloide é uma proteína anormal e insolúvel que se acumula no cérebro de pessoas com Alzheimer. Em um cérebro saudável, a beta-amiloide é processada e removida. No Alzheimer, essa proteína não é adequadamente degradada e eliminada.
2. Placas senis ou neuríticas: Aglomerados de células nervosas mortas ou em degeneração, formadas ao redor de um núcleo central de beta-amiloide.
3. Tranças neurofibrilares: São aglomerados anormais de proteínas dentro dos neurônios que formam estruturas filamentosas e insolúveis.
4. Aumento dos níveis de tau: Refere-se ao acúmulo anormal de tau, uma proteína essencial para a estabilidade dos microtúbulos no cérebro, que, quando alterada, contribui para a formação de tranças neurofibrilares e pode interagir com placas de beta-amiloide.

De acordo com o Manual MSD (2023), as anomalias do tecido cerebral, como a destruição das células nervosas e a redução dos níveis de neurotransmissores, tendem a se desenvolver em todas as pessoas conforme envelhecem. No entanto, essas anomalias são muito mais expressas em pessoas com a Doença de Alzheimer. Os médicos não têm certeza se essas anormalidades cerebrais são a causa da Doença de Alzheimer ou se são o resultado de outro problema que leva tanto à demência quanto às anormalidades no tecido cerebral.

A Doença de Alzheimer, de acordo com Sales (2011) é uma condição cerebral que impacta profundamente as funções mentais, o comportamento e a capacidade funcional das pessoas, distinguindo-se do envelhecimento normal. Diferente das mudanças cerebrais normais associadas ao envelhecimento, o Alzheimer provoca uma deterioração progressiva e patológica. A causa exata da Doença de Alzheimer ainda não é completamente compreendida, e não existem métodos conhecidos para prevenir ou curar a doença. Contudo, há evidências de que certos fatores, como depósitos de beta-amiloide e tranças neurofibrilares, contribuem para a progressão da doença. Em relação ao dano às células nervosas, são particularmente afetadas nas áreas do cérebro responsáveis pela memória, raciocínio e julgamento.

De acordo com a Associação Brasileira de Alzheimer (ABRAZ, 2014), embora a causa exata da Doença de Alzheimer ainda não seja totalmente compreendida, são conhecidas algumas lesões cerebrais características associadas à doença. As principais alterações observadas incluem:

1. Placas senis: São depósitos anormais de proteína beta-amiloide que se acumulam no cérebro. Essas placas interferem na comunicação entre neurônios e contribuem para a degeneração neuronal.
2. Emaranhados neurofibrilares: Formados pela hiperfosforilação da proteína tau, esses emaranhados são agregados de proteínas que afetam o funcionamento dos neurônios e sua capacidade de comunicação.

3. Redução do número de neurônios e sinapses: Há uma diminuição progressiva no número de células nervosas e nas conexões entre elas, levando a uma redução do volume cerebral.

Essas alterações são associadas ao declínio cognitivo e às dificuldades funcionais observadas na Doença de Alzheimer.

Sales (2011) discute que, na Doença de Alzheimer, observa-se uma diminuição dos níveis de acetilcolina, que é fundamental para o controle da memória. Essa redução compromete a função cognitiva, uma vez que a acetilcolina desempenha um papel fundamental na comunicação entre os neurônios relacionados à memória. Além disso, há um aumento do neurotransmissor glutamato, que apesar de ser um mediador importante entre memória e aprendizado, pode causar a morte neuronal quando em excesso. Esse desequilíbrio entre acetilcolina e glutamato contribui para processos patológicos na Doença de Alzheimer. Essas alterações neuroquímicas estão relacionadas à hiperfosforilação da proteína tau e à produção de proteína β -amiloide, que são as principais responsáveis pelo dano celular observado na Doença de Alzheimer.

De acordo com Sereniki (2008), duas principais hipóteses foram propostas para explicar a etiologia da Doença de Alzheimer:

1. Hipótese da Cascata Amiloidal: Esta hipótese sugere que a neurodegeneração na Doença de Alzheimer inicia-se com a clivagem proteolítica da proteína precursora amiloide (APP). Isso resulta na produção, agregação e deposição da proteína beta-amiloide ($A\beta$), que forma placas senis. Essas placas senis são consideradas um dos principais marcadores neuropatológicos da doença e estão associadas ao dano neuronal e à progressão da Doença de Alzheimer.
2. Hipótese Colinérgica: Segundo esta hipótese, a disfunção do sistema colinérgico é suficiente para causar deficiência de memória, similar à observada na Doença de Alzheimer. Estudos mostram que cérebros de pacientes com a doença apresentam degeneração dos neurônios colinérgicos e uma redução dos marcadores colinérgicos. Especificamente, as atividades das enzimas colina acetiltransferase e acetilcolinesterase são reduzidas no córtex cerebral dos pacientes, refletindo o impacto da perda colinérgica na função cognitiva e na memória.

Essas hipóteses ajudam a compreender os mecanismos patológicos e os impactos neuroquímicos associados à Doença de Alzheimer.

Sales (2011) destaca que a Doença de Alzheimer leva a um encolhimento do córtex cerebral, resultando em uma diminuição da área da superfície cerebral. Esta atrofia cerebral é fundamental para a avaliação da doença, pois compromete significativamente a capacidade do indivíduo de pensar e realizar as atividades diárias. A perda de massa cerebral e a redução na área cortical são diretamente responsáveis pelo declínio das

funções cognitivas e pela progressiva perda de autonomia associada à Doença de Alzheimer.

De acordo com Sereniki (2008), as placas senis na Doença de Alzheimer são formadas pela substância beta-amiloide ($A\beta$), e quando esta substância está em altas concentrações, ocorre a formação de fibras amiloidais insolúveis no cérebro. Essas fibras podem se agregar a metais como zinco e cobre, agravando a toxicidade neuronal. Estudos têm mostrado uma correlação entre a presença desses metais, a biologia celular da proteína precursora amiloide (APP) e a neurodegeneração associada à Doença de Alzheimer. Além das placas senis, outra característica neuropatológica importante são os emaranhados neurofibrilares (NFT), que consistem em filamentos helicoidais resultantes da hiperfosforilação da proteína tau. A hipótese da tau sugere que a função normal da proteína tau — que é estabilizar os microtúbulos neuronais — é prejudicada na Doença de Alzheimer. Com o tempo, os microtúbulos neuronais saudáveis são substituídos gradualmente por esses emaranhados neurofibrilares, comprometendo a estrutura e a função dos neurônios afetados.

3.4 TERAPIAS ATUAIS

O tratamento das demências envolve uma abordagem multidisciplinar que pode incluir intervenções farmacológicas, terapias não farmacológicas, suporte psicossocial e modificações no estilo de vida. Vale ressaltar que o tratamento específico pode variar de acordo com o tipo de demência e as necessidades individuais do paciente.

3.4.1 FARMACOLÓGICAS

O tratamento da Doença de Alzheimer combina abordagens farmacológicas (o uso de agentes que melhoram sintomas específicos) e não farmacológicas para gerenciar os sintomas e melhorar a qualidade de vida dos pacientes (VENTURA et al., 2010).

Atualmente, a Agência Nacional de Vigilância Sanitária (ANVISA) licencia quatro medicamentos para o tratamento da Doença de Alzheimer que pertencem à classe dos inibidores da acetilcolinesterase (AChEI): tacrina, rivastigmina, donepezil e galantamina. Esses medicamentos funcionam ao aumentar a disponibilidade de acetilcolina, um neurotransmissor importante para a função cognitiva, ao inibir a enzima acetilcolinesterase, que a degrada. Além disso, a memantina é outro medicamento licenciado, que atua como um antagonista não competitivo dos receptores NMDA. Esse medicamento protege os neurônios contra a excitotoxicidade causada pelo glutamato, que é um dos fatores envolvidos na degeneração neuronal observada na Doença de Alzheimer (Engelhardt et al., 2005). Essas abordagens farmacológicas são fundamentais no manejo dos sintomas e na moderação da progressão da doença.

De acordo com Xia et al. (2010), a memantina é um derivado do adamantano que atua como um antagonista dos receptores NMDA, sendo amplamente utilizada no tratamento da Doença de Alzheimer devido ao seu excelente perfil de segurança clínica. A sua ação é específica na neurotoxicidade mediada pela atividade excessiva dos

receptores NMDA, bloqueando as correntes sinápticas excitotóxicas que contribuem para a degeneração neuronal. O diferencial da memantina reside no fato de que, devido ao seu antagonismo não competitivo, ela consegue bloquear a atividade excessiva dos receptores NMDA sem interferir na neurotransmissão normal. Isso permite que a função sináptica saudável seja preservada, minimizando os efeitos colaterais enquanto oferece proteção neuroprotetora significativa (Xia et al., 2010).

Pesquisas laboratoriais têm explorado os benefícios terapêuticos da combinação de memantina com inibidores da acetilcolinesterase (AChEI) no tratamento da Doença de Alzheimer. A memantina atua eliminando a disfunção da transmissão glutamatérgica, ao passo que os AChEIs aumentam os níveis de acetilcolina, que estão reduzidos na doença. Estudos pré-clínicos indicam que, ao agirem por vias diferentes mas patologicamente interligadas, essas duas classes de medicamentos podem complementar-se de maneira eficaz. A combinação desses tratamentos pode resultar em efeitos terapêuticos superiores em comparação ao uso isolado de cada droga, devido à sua atividade complementar (Parsons et al., 2013). Isso sugere um potencial significativo para melhorar os resultados no manejo da Doença de Alzheimer através de terapias combinadas.

Em junho de 2021, a Sociedade Brasileira de Geriatria e Gerontologia (SBGG) anunciou a aprovação de um novo medicamento para a Doença de Alzheimer pela FDA (*Food and Drug Administration*), a primeira em 18 anos. O medicamento aprovado é o Aducanumab, um anticorpo monoclonal humano desenvolvido pela Biogen. O Aducanumab é indicado para o tratamento da Doença de Alzheimer nas fases de comprometimento cognitivo leve e demência leve. Seu mecanismo de ação é direcionado contra a proteína beta-amiloide, que se acumula no cérebro dos pacientes com a doença e está associada à neurodegeneração. Ao combater a beta-amiloide, o Aducanumab busca reduzir a progressão dos sintomas da Doença de Alzheimer.

Os estudos divulgados indicam que o uso do Aducanumab em pacientes com o diagnóstico da Doença de Alzheimer pode resultar em uma redução estimada de 20 a 30% no declínio causado pela doença. Essa redução foi medida por meio de exames de neuroimagem e testes específicos, como o CDR (Clinical Dementia Rating), ADCS-ADL (Alzheimer's Disease Cooperative Study-Activities of Daily Living) e NPI (Neuropsychiatric Inventory). O Aducanumab atua especificamente na redução do acúmulo extracelular da proteína beta-amiloide, uma das alterações patológicas da Doença de Alzheimer. No entanto, ele não interfere nos transtornos relacionados à proteína TAU, que também são relevantes na progressão da doença. Dessa forma, é reconhecido que um tratamento eficaz para a Doença de Alzheimer deve abordar ambas as alterações patológicas, não se limitando apenas a uma delas.

Talvez se acabe demonstrando que o aducanumab retarda a progressão da doença de Alzheimer. No entanto, de acordo com outros, mais evidências são necessárias para mostrar que ele reduz os sintomas e retarda a progressão da doença de Alzheimer.

3.4.2 NÃO FARMACOLÓGICAS

As terapias não farmacológicas para o tratamento da Doença de Alzheimer incluem uma diversidade de abordagens que têm como objetivo principal melhorar a qualidade de vida dos pacientes e retardar o progresso dos sintomas. Entre as opções disponíveis, destacam-se: (A) Estimulação multissensorial, que envolve a ativação dos sentidos por meio de diferentes estímulos; (B) Estimulação cognitiva, que busca manter e melhorar as capacidades mentais; e (C) Exercícios físicos, que promovem benefícios físicos e cognitivos. Além disso, técnicas como musicoterapia e arteterapia oferecem aos pacientes oportunidades de expressão emocional e criativa. Outras abordagens incluem o treinamento cognitivo, focado em exercícios mentais estruturados, e a terapia de reminiscências, que envolve a evocação de memórias passadas para fortalecer a identidade pessoal e promover o bem-estar. Essas terapias são geralmente parte de um trabalho multiprofissional que envolve profissionais como fisioterapeutas, enfermeiros, nutricionistas, profissionais de educação física, e assistentes sociais, entre outros. Essa colaboração interdisciplinar é essencial para proporcionar um tratamento holístico e personalizado, atendendo às necessidades físicas, cognitivas e emocionais dos pacientes (Caixeta, 2012; Malloy-Diniz; Fuentes; Cosenza, 2013; Sayeg, 2009).

Serão apresentadas algumas estratégias que podem ser encontradas em diversas literaturas e são recomendadas para aqueles interessados no campo das demências e suas terapêuticas:

Treino Cognitivo - É um conceito que se refere a métodos e práticas projetados para melhorar ou manter funções cognitivas específicas, como memória, atenção, raciocínio e resolução de problemas, planejamento e organização. De acordo com Diller e Gordon, como citado por Abrisqueta-Gomez e Santos, o treinamento cognitivo visa fornecer aos pacientes um repertório comportamental necessário para resolver problemas ou realizar tarefas que podem ser desafiadoras. (apud ABRISQUETA-GOMEZ; SANTOS, 2006).

Técnicas Compensatórias - São abordagens usadas para ajudar indivíduos a gerenciar e superar déficits cognitivos, promovendo a autonomia e a qualidade de vida. Essas técnicas visam compensar as funções cognitivas prejudicadas, permitindo que os pacientes mantenham a independência e a participação nas atividades diárias. Elas podem ser aplicadas em várias áreas, incluindo atividades de vida diária e participação social. Essas técnicas ajudam a criar um ambiente adaptado às necessidades do indivíduo e promovem a manutenção da funcionalidade e da qualidade de vida, mesmo diante das limitações impostas pela doença.

Terapia de orientação para a realidade – É uma abordagem terapêutica desenvolvida para ajudar indivíduos com demência, como a Doença de Alzheimer, a manter a consciência e a orientação em relação ao tempo e ao espaço, reduzindo a confusão e melhorando a qualidade de vida. Criada por Folson em 1968, a TOR tem como objetivo principal ajudar os pacientes a se orientarem melhor em seu ambiente e contexto diário. (MONTEIRO; COVRE; FUENTES, 2013).

Técnicas de atividades ludoterápicas - Conhecida também como ludoterapia, utilizam brinquedos e atividades recreativas no tratamento de pacientes com demência, como a Doença de Alzheimer. O objetivo é proporcionar um ambiente terapêutico que estimule a interação e a expressão emocional, melhorando a qualidade de vida e o bem-estar dos pacientes. Aqui estão alguns aspectos importantes sobre essas técnicas.

As técnicas de atividades ludoterápicas são uma ferramenta valiosa no tratamento da demência, oferecendo uma abordagem não invasiva e agradável que pode complementar outras formas de terapia e cuidados.

3.4.3 ARTETERAPIA

A arteterapia, quando usada no tratamento de pessoas com doença de Alzheimer, busca alcançar vários objetivos importantes. De acordo com Killick e Allan, essa abordagem terapêutica busca “fornecer estímulo significativo, melhorar as condições de interação social e os níveis de autoestima” dos pacientes (apud TAVEIRA; TAVEIRA; CAIXETA, 2012).

A arteterapia oferece atividades que envolvem expressão criativa, como pintura, desenho e escultura, que podem estimular as capacidades cognitivas quanto motoras dos pacientes. Essas atividades ajudam a manter o cérebro ativo promovendo a saúde mental ao engajar diferentes áreas do cérebro, contribuindo para a preservação das funções cognitivas. Essa abordagem utiliza a criatividade como ferramenta para melhorar o bem-estar emocional e social dos pacientes com a Doença de Alzheimer, promovendo uma experiência enriquecedora e terapêutica.

Mello e Rodrigues (2012) destacam que a aplicação de técnicas de arteterapia no tratamento de demências oferece aos pacientes a chance de autoexpressão e a possibilidade de fazer escolhas, o que é fundamental para estimular o paciente. Essas técnicas, ao permitir que os indivíduos expressem suas emoções e façam escolhas, não só estimulam o cérebro de maneira criativa, mas também ajudam a melhorar a qualidade de vida dos indivíduos com demência, promovendo um ambiente terapêutico mais enriquecedor.

Musicoterapia – Pode ser entendida como "uma intervenção que se utiliza de música para promover melhora na qualidade de vida do indivíduo, bem como seu maior desempenho nos aspectos biopsicossociais" (CASCARANI, 2013). Essa abordagem terapêutica pretende melhorar não apenas a qualidade de vida, mas também o desempenho em diversas áreas, incluindo: (A) Aspectos biológicos; (B) Aspectos psicológicos; (C) Aspectos sociais.

Ao usar a música de forma estruturada e personalizada, a musicoterapia oferece uma abordagem holística para apoiar o bem-estar dos pacientes com Doença de Alzheimer. Esta forma de terapia leva em conta as necessidades individuais de cada paciente, usando melodias, ritmos e letras que refletem com suas experiências pessoais e preferências musicais.

De fato, a música tem um impacto significativo nos pacientes com Doença de Alzheimer, mesmo quando eles estão em estágios avançados da doença. Como menciona SAYEG (2009, p. 307), "os pacientes demenciados que sempre gostaram de música continuarão gostando, mesmo doentes". Isso ocorre porque a música pode acessar memórias e emoções profundas que permanecem preservadas, oferecendo conforto e uma conexão emocional. A familiaridade com a música e o prazer que ela proporciona pode ajudar a aliviar sintomas e melhorar o estado de ânimo e promover interações sociais.

Além disso, Mello e Rodrigues (2012, p. 294) destacam que "vários estudos feitos nesse campo revelam benefícios aos pacientes". Esses benefícios incluem: (A) Melhora na qualidade de vida: A musicoterapia pode proporcionar uma experiência emocionalmente rica; (B) Estimulação cognitiva: A exposição à música pode ajudar a ativar as áreas do cérebro relacionadas à memória e à percepção; (C) Promoção da interação social: A musicoterapia pode facilitar a comunicação e o engajamento social.

Essa técnica tem sido eficaz no tratamento de pacientes com Alzheimer, especialmente aqueles que apresentam confusão, agitação e distúrbios do sono. Sayeg (2009), indica que essa técnica possui um excelente efeito relaxante, o que torna um recurso valioso no manejo da doença.

Abordagem emocional - orientada - Conforme Caixeta (2012) essa técnica terapêutica tem sido frequentemente utilizada em pacientes com a Doença de Alzheimer para abordar questões emocionais e comportamentais. Essa técnica é mencionada como uma forma de lidar com a perda, melhorar o humor e o comportamento, fortalecer os laços sociais e melhorar a qualidade de vida dos pacientes.

Essa abordagem reconhece a importância das emoções na experiência da doença de Alzheimer. Em vez de se focar apenas nos aspectos cognitivos da doença, a abordagem emocionalmente orientada busca: (A) Validar e compreender as emoções; (B) Oferecer um ambiente seguro; (C) Utilizar técnicas terapêuticas específicas.

Terapia das reminiscências - Essa terapia tem como objetivo "melhorar o funcionamento intrapessoal e interpessoal dos pacientes ao facilitar a revivência, estruturação, integração e troca de lembranças" (TAVEIRA; TAVEIRA; CAIXETA, 2012, p. 358). Ela promove a discussão de eventos e atividades passadas, os pacientes têm a oportunidade de reviver memórias significativas, o que pode ajudar a fortalecer a identidade pessoal e social, melhorar o humor e reduzir sentimentos de isolamento. Para enriquecer essas sessões, são utilizados vários auxílios suplementares como fotos, músicas, álbuns, jornais antigos e itens de uso pessoal.

É fundamental adaptar as intervenções à medida que a Doença de Alzheimer progride é essencial para garantir que o tratamento continue sendo eficaz e significativo para o paciente. A abordagem colaborativa entre profissionais de saúde, familiares e cuidadores é fundamental para proporcionar a melhor qualidade de vida possível para aqueles que vivem com demência.

3.5 A MUSICOTERAPIA NA DOENÇA DE ALZHEIMER

Segundo Cunha (1999), as sessões de Musicoterapia oferecem aos pacientes um ambiente onde podem reorganizar suas capacidades cognitivas, afetivas e corporais. Durante essas sessões, os pacientes têm a chance de: Expressar-se e comunicar-se, através das canções, movimentos e da percussão em conjunto. Nesse período, a pessoa pode entrar em contato com suas memórias e emoções, percebendo-se e manifestando-se de acordo com sua possibilidade motora e cognitiva atual.

Para que a Musicoterapia seja eficaz no tratamento de pessoas com Doença de Alzheimer, é fundamental que o musicoterapeuta tenha um entendimento profundo da história de vida e dos interesses dos pacientes. Conhecer o repertório musical significativo para cada indivíduo permite que o terapeuta escolha músicas que não apenas evocam memórias, mas também promovem um envolvimento mais profundo durante as sessões.

A musicoterapia, mesmo em estágios avançados de demência, oferece uma forma de comunicação e conexão para os pacientes que estão enfrentando dificuldades com a comunicação verbal. Durante os estágios da doença, a memória afetiva e a sensibilidade a sinais não verbais tornam-se mais expostas. (VARGAS, 1983). Mesmo quando as funções cognitivas e comunicativas estão comprometidas, a música oferece uma estrutura clara que pode ser compreendida e observada pelos pacientes. Os elementos musicais, como a melodia, o ritmo e as variações de intensidade, refletem características da linguagem falada, tornando-se uma ponte entre a expressão emocional e a percepção do paciente.

A música, como instrumento terapêutico, exerce uma influência significativa sobre o cérebro, estimulando e mobilizando diversas áreas cerebrais, o que a torna uma poderosa ferramenta para o bem-estar e reabilitação de indivíduos, especialmente em contextos terapêuticos. De acordo com Rosado (2016), quando utilizada corretamente, a música pode ser transformadora, contribuindo para o funcionamento e a saúde cerebral por meio do exercício musical. Na proposta terapêutica, a música atua para promover mudanças estruturais, funcionais e de padrões de conectividade. Conforme observado por Palazzi (2015), a música também influencia os padrões de conectividade neural. Ao envolver o cérebro na codificação e decodificação musical, a música pode fortalecer ou modificar as conexões entre diferentes regiões cerebrais. Isso pode ser particularmente benéfico para pacientes cujas áreas cerebrais específicas foram afetadas por doenças ou lesões.

A musicoterapia, ao focar na evocação da memória musical do paciente, oferece uma abordagem terapêutica personalizada para pacientes com Alzheimer. Para isso, os profissionais da área de saúde devem construir um perfil do paciente, baseado em uma anamnese mais detalhada incluindo sua história de vida e as experiências musicais do indivíduo. Sampaio et al. (2015) destacam a importância de reconstruir essa história de vida do indivíduo, trazendo-o para o centro do seu tratamento. A música, ao evocar lembranças, causam bem-estar ao paciente e facilita a comunicação, mostrando as

contribuições significativas que a prática da musicoterapia pode oferecer no tratamento do Alzheimer (Barbosa & Cotta, 2017).

Pode-se afirmar que a musicoterapia utiliza a música e seus elementos de maneira estruturada para construir técnicas terapêuticas, geralmente realizadas por profissionais qualificados e treinados para ajudar esses pacientes (Torcate et al., 2020). É um processo de relação terapêutica onde os profissionais personalizam o atendimento de acordo com as necessidades individuais de cada paciente. Martins (2017) comenta que as técnicas de musicoterapia têm como objetivo melhorar a comunicação, abrangendo para esferas sociais e cognitivas. Além disso, por ser um tratamento não invasivo e de baixo custo, a musicoterapia é eficaz na promoção e prevenção da saúde mental e física, e pode ser utilizado tanto na reabilitação quanto para um tratamento contínuo.

A aplicação da musicoterapia se destaca como uma intervenção terapêutica significativa, ela utiliza a música como uma ferramenta expressiva e de um grande potencial terapêutico. De acordo com Barbosa e Cotta (2017), a musicoterapia é um recurso terapêutico e pode ser considerado como uma terapia expressiva. Nesse caso, a música é utilizada para integrar às vivências do paciente, e com a intervenção do terapeuta, esse processo tem como potencial promover melhorias na saúde do paciente. A utilização da musicoterapia como um método de mediação e intervenção, destaca a importância de reconhecer os benefícios que essa abordagem terapêutica pode oferecer, seja na promoção do bem-estar quanto na melhoria da qualidade de vida dos pacientes.

3.6 EMOÇÕES EM PACIENTES COM DEMÊNCIA

De acordo com Sacharin, Schlegel e Scherer (2012), as emoções são respostas do organismo a eventos do ambiente, envolvendo aspectos cognitivos e comportamentais, além do sistema autonômico simpático e parassimpático, que controlam as ações do organismo. Essas emoções desempenham um papel importante nas interações sociais, influenciando a comunicação e a adaptação ao meio. No entanto, Barrett (2017), define as emoções como percepções subjetivas, moldadas pelas experiências e interpretações individuais.

A conceituação da emoção como uma descarga psíquica de breve duração, conforme descrita por Scherer (2005), é amplamente aceita entre os teóricos das emoções. As emoções são vistas como reações intensas e momentâneas a estímulos específicos, diferindo de outros estados afetivos, como sentimentos, que são mais duradouros e menos intensos. Scherer destaca que as emoções são respostas adaptativas que envolvem mudanças no estado físico e mental do indivíduo, muitas vezes desencadeadas por uma avaliação rápida e automática de eventos. De acordo com Andersen e Guerrero (1998), essas emoções básicas são aquelas que têm maior probabilidade de serem expressas e reconhecidas de maneira semelhante em diferentes culturas.

Magalhães (2013), é um autor português notável no estudo das emoções, ele define a emoção como uma resposta automática, intensa e rápida, que pode ser

inconsciente ou consciente, gerada em resposta a um estímulo. Esse impulso neuronal provoca uma ação no organismo. As emoções desempenham funções essenciais ligadas à adaptação e à expressão, atuando como um catalisador que mediam a conduta e o ambiente.

A literatura nos mostra diferentes abordagens para a classificação das emoções humanas básicas. Barrett (2006), apresenta as emoções básicas como sendo: alegria, tristeza, raiva, medo, nojo e felicidade. Averill (1975), sugere que outras emoções podem ser entendidas como combinações ou variações das emoções básicas. Além do mais, Collins, Ortony e Clore (1988) oferecem uma classificação mais simples, dividindo as emoções em dois grupos de emoções básicas: as positivas e as negativas.

De acordo com as teorias sobre as emoções, sejam elas agradáveis ou desagradáveis, podem ser consideradas emoções básicas, desde que elas sejam inatas, geneticamente programadas e desempenhem um papel essencial na sobrevivência do organismo.

Magalhães (2007) oferece uma visão mais detalhada e útil das emoções, para entender como elas influenciam o comportamento e o estado físico. A Tristeza é descrita como uma emoção que provoca sentimentos de mágoa, desânimo, melancolia, desilusão, desamparo, desespero e desalento. A Alegria é uma emoção que estimula a atividade no centro cerebral, levando a sensações de prazer, diversão, satisfação e euforia. No que diz respeito a Raiva, ela é caracterizada pela afluência de sangue para as mãos e pela ativação hormonal que acelera a atividade cardíaca. Em relação ao Medo, envolve a concentração de sangue nas pernas e um rosto cintilante, resultando em ansiedade, apreensão e nervosismo. (Magalhães, 2007). A habilidade de identificar, diferenciar e compreender essas emoções é essencial para a regulação emocional adequada e uma melhor compreensão do impacto das emoções no comportamento e no estado físico (Vaz, 2009).

É fundamental ter o entendimento do quanto é necessário saber reconhecer as emoções nas pessoas ao nosso redor. Pois, o reconhecimento das emoções é uma habilidade essencial não apenas para a adaptação social e o bem-estar individual, mas também para o desenvolvimento de ambientes de trabalho e sociais mais colaborativos e harmoniosos. Reconhecer as emoções nas pessoas permite uma comunicação mais empática e eficaz.

Segundo os autores Lopes, Brackett, Nezlek, Schütz e Salovey (2004), citados por Woyciekoski & Hutz (2009), destacam que as competências emocionais são essenciais nas relações interpessoais. As emoções desempenham papéis importantes na comunicação e nas funções sociais, passando informações sobre pensamentos e intenções. Essas competências envolvem as habilidades, como a expressão, regulação e compreensão das emoções, são essenciais para interações eficazes e para o desenvolvimento de relacionamentos saudáveis, conforme descrito por Denham (2007) e Halberstadt, Denham & Dunsmore (2001).

Os componentes da competência emocional exercem um papel importante no sucesso das relações interpessoais, apoiando habilidades, como ouvir, cooperar, pedir ajuda, integrar-se em grupos pequenos e negociar conflitos (Denham, 2007). Essas interações bem-sucedidas promovem relações mais saudáveis, contribuem para a saúde mental e o bem-estar ao longo da vida (Denham, 2007).

Ekman (2011) discute sobre a influência das emoções na qualidade de vida das pessoas, ressaltando que elas estão presentes em todos os aspectos dos relacionamentos humanos, desde o trabalho até as relações íntimas. Ele observa que as emoções tem um papel essencial na forma como as pessoas interagem e reagem em meio a diversas situações. Por um lado, as emoções podem contribuir para o bem-estar e satisfação; por outro, elas podem levar a comportamentos que, mesmo que pareçam apropriados, podem causar um prejuízo futuro.

A visão de Silva (2011) e Goleman (1995) sobre emoções destaca seu papel primordial na adaptação cotidiana e na motivação pessoal. Silva enfatiza como as emoções ajudam o indivíduo a reagir a perigos e a buscar melhorias, enquanto Goleman vê as emoções como impulsos naturais que orientam nossas ações e decisões, integrando-as no contexto evolutivo. Essa perspectiva é útil para entender como as emoções influenciam a nossa interação com o mundo e nossas motivações internas.

Os pacientes portadores de demências frequentemente experimentam uma variedade de emoções devido às alterações no cérebro que afetam a cognição, memória e habilidades de comunicação. Essas emoções podem variar dependendo do estágio da demência, do tipo específico de demência e das condições individuais de cada paciente. Esses pacientes não têm a mesma habilidade que pessoas saudáveis em lidar com frustrações, medo, entre outras emoções, geradas em situações cotidianas. Os circuitos neurológicos são mais escassos e isso por si só pode se manifestar comportamentos considerados anormais.

Em relação aos trabalhos encontrados, Vale ressaltar sobre a dificuldade de encontrar literatura sobre o assunto em questão, pois não tem muitos artigos que abordam de forma específica sobre o a expressão das emoções de pacientes com demências. A maior parte dos trabalhos apresentados, se referem a demanda dos profissionais de saúde ou da visão dos cuidadores que acompanham esse público, que são os pacientes com demência.

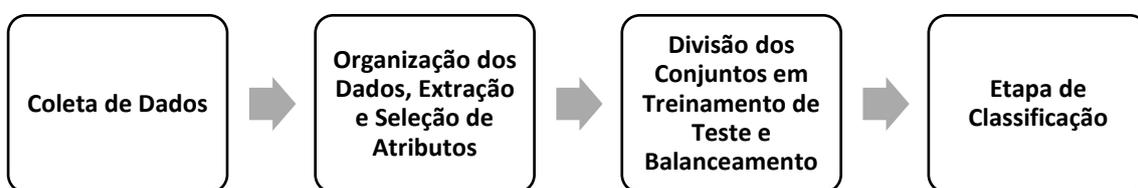
É importante notar que as emoções dos pacientes com demência podem ser influenciadas por fatores externos, como o ambiente ao redor, a qualidade dos cuidados prestados, a interação com cuidadores e familiares, entre outros. Abordagens de cuidado centradas na pessoa, compreensão, paciência e adaptação às necessidades individuais podem ajudar a melhorar o bem-estar emocional desses pacientes. Além disso, o suporte emocional aos familiares e cuidadores também desempenha um papel crucial no manejo da demência.

CAPÍTULO 4

4. METODOLOGIA

Neste capítulo vão ser apresentados a coleta de dados em conjunto com a descrição das etapas dos métodos de Extração e Seleção de Atributos com os Algoritmos Genéticos e Otimização por Enxame de Partículas, englobando desde a divisão dos conjuntos em Treinamento de Teste e Balanceamento até a etapa de classificação dos classificadores utilizados. O diagrama abaixo ilustra as etapas da metodologia adotada.

Figura 1 – Diagrama das etapas da metodologia.



Fonte: A autora (2024)

4.1 DADOS SOBRE A COLETA

Foi feito um estudo experimental com amostras independentes. As coletas de dados com os voluntários com mais de 60 anos, com e sem demência, foram realizadas no Laboratório de Computação Biomédica do Departamento de Engenharia Biomédica e no Ambulatório de Neurologia do Hospital das Clínicas, ambos da Universidade Federal de Pernambuco (UFPE). O protocolo proposto foi submetido e aprovado na análise ética dos Comitês de Ética em Pesquisa (CEP) das instituições vinculadas ao estudo: Universidade de Pernambuco (UPE), Universidade Federal de Pernambuco (UFPE) e Hospital das Clínicas da UFPE (HCPE), cujos registros são, respectivamente: 42381720.6.0000.5207; 42381720.6.3001.5208; e 42381720.6.3002.8807.

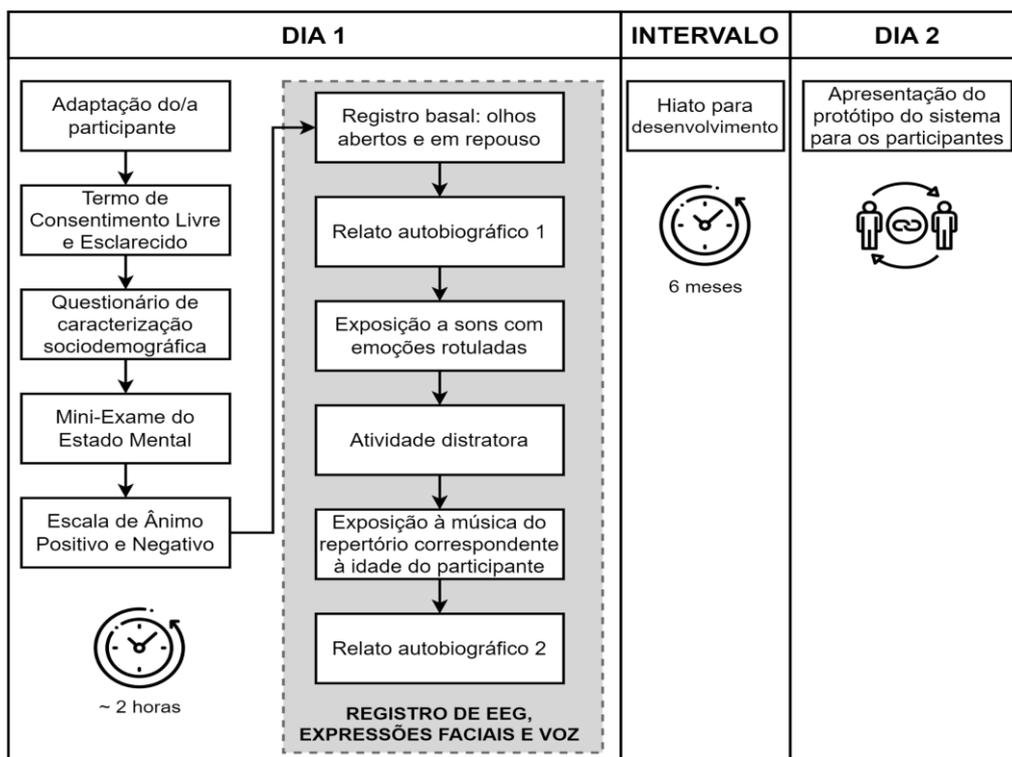
Para ser melhor ilustrado, o processo experimental foi dividido nas seguintes etapas: (1) Reconhecimento, (2) Coleta e (3) Retorno aos participantes. As etapas 1 e 2 são realizadas em um mesmo dia, enquanto que a etapa 3 se dá aproximadamente 6 meses após a coleta.

1. **Reconhecimento** - Tem o objetivo de ajudar no processo de adaptação do voluntário ao ambiente onde será feita a coleta de dados e aos demais participantes da pesquisa. Nesta etapa é feito o preenchimento da ficha de cadastro e o mini - exame do estado mental (MEEM), os experimentos serão explicados e demonstrados e estando em comum acordo o voluntário assina o termo de

consentimento livre e esclarecido. O tempo estabelecido da coleta é de 1 hora de duração, mas pode durar até 2 horas.

2. **Coleta** - Nesta etapa é feito o registro de sinais fisiológicos (EEG e frequências cardíaca e respiratória), como também a gravação de voz e vídeo do voluntário. Esse registro é realizado em duas etapas: (1) Relato autobiográfico do voluntário e (2) O voluntário tem o contato com alguns ritmos e gêneros musicais escolhidos.
3. **Retorno ao participante** - Nesta etapa são apresentados, aos participantes, os achados do estudo, fornecendo ainda uma lista de músicas recomendadas, de acordo com a faixa etária e gostos dos participantes.

Figura 2 – Protocolo para coleta de dados.



Fonte: SANTANA (2023)

4.1.1 AMOSTRA DE PARTICIPANTES

Em relação ao quantitativo de participantes, foram realizadas coletas com 39 indivíduos, divididos em dois grupos:

1. **Grupo TCM (Transtorno Cognitivo Menor)** - 18 participantes a partir de 60 anos diagnosticados com demência leve a moderada.
2. **Grupo Controle (sem histórico de doenças encefálicas)** - 21 voluntários a partir de 60 anos sem histórico de demência.

Em ambos os casos, os indivíduos deveriam ser capazes de escutar e responder adequadamente a comandos simples, além de não possuir histórico de traumatismo crânio-encefálico, doença de Parkinson, acidente vascular encefálico ou crises convulsivas.

4.1.2 RECRUTAMENTO DOS PARTICIPANTES

Os participantes da pesquisa foram convocados a partir de ambulatórios de Neurologia, Clínicas de cuidado ao idoso e também através da divulgação feita por meio de anúncios nas redes sociais e na mídia eletrônica.

4.1.3 INSTRUMENTO DE COLETA DE DADOS

O Mini-exame do estado mental (MEEM) é um tipo de teste cognitivo que tem como objetivo avaliar de forma rápida (em torno de 10 minutos), a função cognitiva de um indivíduo. Ele é de fácil aplicação e pode ser utilizado para avaliar se o indivíduo tem algum tipo de déficit cognitivo, como também a função mental do idoso com demência ao passar do tempo. O MEEM é utilizado como instrumento de rastreio, ele não substitui uma avaliação mais detalhada e apesar de ele avaliar vários domínios (orientação espacial, temporal, memória imediata e de evocação, cálculo, linguagem-nomeação, repetição, compreensão, escrita e cópia de desenho), não serve como teste diagnóstico. O ponto de corte caso/não caso para o grupo TCM foi de 19/20 para indivíduos sem escolaridade e 23/24 para indivíduos com escolaridade, de acordo com critérios estabelecidos para população brasileira (ALMEIDA, 1998). De maneira complementar, foram classificados como do grupo controle os indivíduos com escore mínimo de 20 (sem escolaridade) e 24 (com escolaridade) no MEEM.

4.1.4 PROCEDIMENTOS PARA COLETA DE DADOS

Registro de eletroencefalografia (EEG) - A base de dados foi construída através da aquisição de sinais dos voluntários do estudo, durante o relato autobiográfico e da exposição à música. O sinal eletroencefalográfico foi captado através de 23 eletrodos, em touca de neoprene, com uso de gel para reduzir a impedância, por um equipamento Neurovirtual, modelo Brain Wave III. Em relação ao tempo de registro, ficaram em torno de 20 minutos, sendo 2 minutos de registro basal (com paciente em repouso de olhos abertos); seguido de um primeiro relato autobiográfico; exposição a 3 sons com emoção-alvo pré-definida (tristeza, felicidade e medo); atividade distratora entre estímulos; exposição à música; e segundo relato autobiográfico.

Figura 3 – Equipamentos utilizados para registro dos dados (Módulo de EEG).



Fonte: SANTANA (2023)

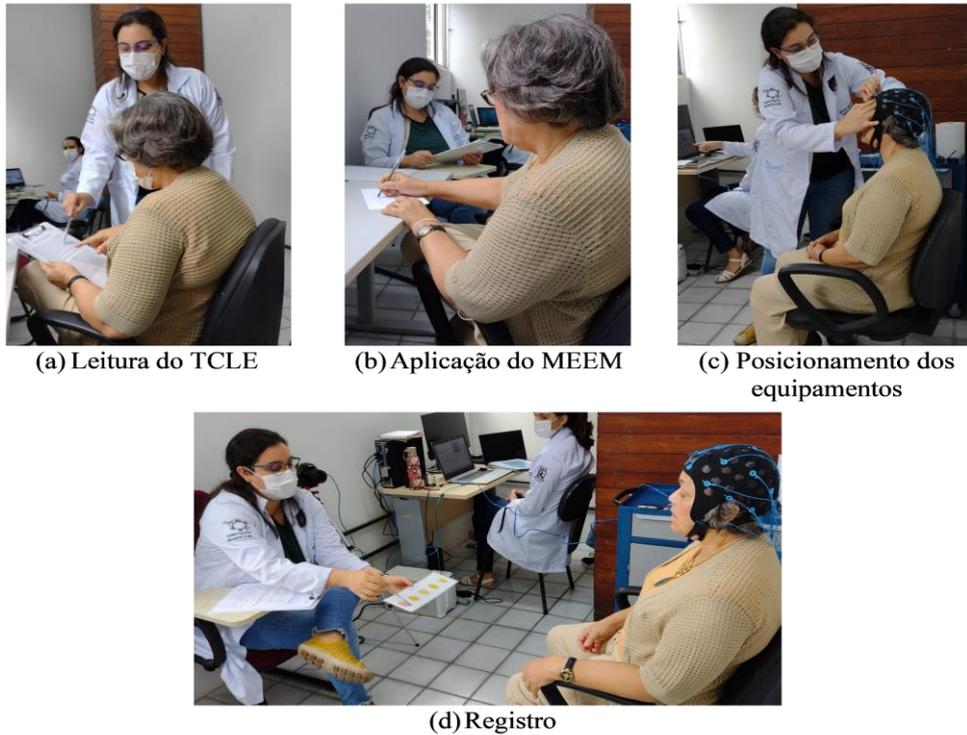
Registro de áudio e vídeo - Os registros de áudio e vídeo foram feitos de maneira simultânea, com o uso de uma câmera fotográfica DSRL Canon EOS Rebel T7. Onde todo o processo do relato autobiográfico e da exposição à música foram filmados. Antes de começar todo o registro, de início tudo é explicado ao voluntário detalhadamente, todos os instrumentos físicos e critérios de classificação utilizados. Depois disso, o voluntário é convidado a assinar o termo de consentimento livre e esclarecido (TCLE) em comum acordo e liberando o uso da sua imagem.

Figura 4 – Equipamento utilizado para registro dos dados (Câmera Fotográfica).



Fonte: FOCUSFOTO.COM.BR

Figura 5 – Etapas do procedimento de coleta de dados.

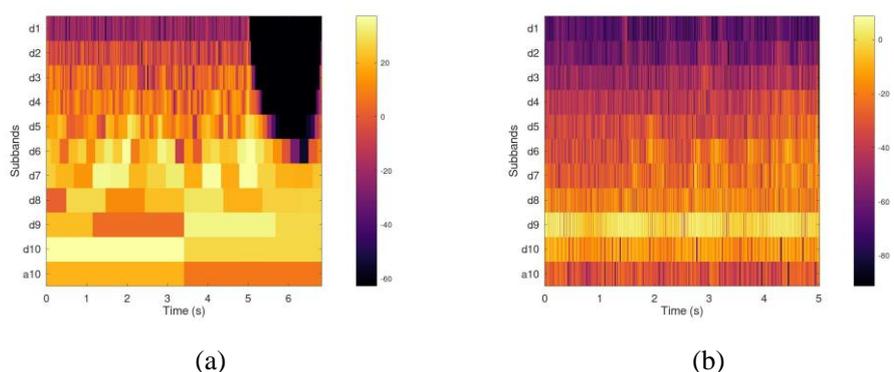


Fonte: SANTANA (2023)

4.2 ORGANIZAÇÃO DA BASE DE DADOS

Inicialmente os sinais de ambas as modalidades passaram por uma etapa de janelamento, onde foi utilizada uma janela de 5 segundos com sobreposição de 1 segundo. Essa técnica de janelamento é muito comum no processamento de sinais, pois é utilizada para analisar características locais e temporais desses sinais. A sobreposição garante que não exista a perda de informação entre as janelas. Em seguida, cada janela foi convertida em imagem usando a Transformada de Wavelets, uma ferramenta poderosa para analisar sinais em diferentes escalas de resolução, destacando características como transientes e frequências. A representação em imagem favorece a utilização de redes neurais profundas, as quais são conhecidas na literatura por exibir bons desempenhos de classificação. Assim, foi utilizada uma base de dados de imagens provenientes de sinais de EEG e outra de sinais de voz, conforme exemplos da Figura 6. Essas imagens foram, então, submetidas ao processo de extração de atributos a partir de uma rede neural profunda pré-treinada, para isso foi utilizada apenas a configuração da LeNet pré-treinada com a base MNIST, que extrai 500 atributos da imagem de entrada. Para o desenvolvimento desta etapa, foi utilizado o *software* Weka.

Figura 6 – Exemplos de imagens geradas a partir dos sinais de (a) EEG e (b) voz.



Fonte: A autora (2024)

Os vetores de atributos extraídos de cada sinal de EEG e voz de cada participante foram concatenados entre si, sendo associados também os atributos de idade, gênero e diagnóstico do indivíduo. Assim, cada instância passou a ser representada por um único vetor composto por 1003 atributos: 500 advindos do sinal de EEG, 500 do sinal de voz, e os últimos 3 referentes a idade, gênero e diagnóstico, respectivamente. Cada instância foi também associada à sua classe de estado afetivo: positivo, negativo ou neutro. Esses sentimentos foram obtidos a partir da avaliação dos relatos autobiográficos finais (RAB2), correspondendo a um recorte da base de dados (baseMultimodal_RAB2_classA) organizada em instâncias que se dividem em negativo (174 instâncias), neutro (48 instâncias) e positivo (2536 instâncias).

Essa base foi dividida em 75% das instâncias para treinamento e 25% para teste. O conjunto de treinamento foi balanceado utilizando o SMOTE (*Synthetic Minority Oversampling Technique*, Técnica de Sobreamostragem Sintética da Minoritária). Usando o SMOTE, são geradas instâncias sintéticas das classes minoritárias de forma a que a quantidade de instâncias por classe fique equilibrada. Essas instâncias sintéticas são calculadas a partir das instâncias reais existentes na base de dados (FERNÁNDEZ et al., 2018).

4.3 CLASSIFICAÇÃO

Nesta etapa, os subconjuntos gerados foram submetidos à classificação. Os métodos utilizados para serem investigados foram: o Bayes Net, Naive Bayes, árvore de decisão J48, Random Tree e Random Forest (100, 200, 300, 400 e 450 árvores). O conjunto de treino balanceado com SMOTE foi utilizado para investigar o possível melhor método de classificação. Foi utilizada a validação cruzada com 10 *folds*, repetida 30 vezes.

4.4 ANÁLISE DOS MÉTODOS

Para a análise dos desempenhos dos algoritmos, foi gerada uma tabela contendo a redução estatística dos dados obtidos nas planilhas de resultados do *software* WEKA e também foram plotados gráficos de diagrama de caixa (*boxplot*), que foram gerados no *software* Jamovi, considerando os resultados das mesmas planilhas, considerando as métricas de acurácia, sensibilidade, especificidade, índice kappa e área sob a curva ROC.

4.5 SELEÇÃO DE ATRIBUTOS

A seleção de atributos é um passo importante para melhorar o desempenho dos classificadores, pois pode reduzir a dimensão dos dados e eliminar as características que são irrelevantes, o que pode levar a uma maior precisão e eficiência dos modelos. Para o desenvolvimento desta etapa, foi utilizado o *software* Weka, na versão 3.9.6. É uma ferramenta livre usada como arquivo padrão para as tarefas de mineração de dados no formato ARFF - Formato de Arquivo de Relação de Atributos. Foram investigados os seguintes métodos de seleção de atributos: Algoritmo Genético (AG) e Otimização por Enxame de Partículas (*Particle Swarm Optimization*, PSO).

A aplicação do AG resultou em uma seleção de 209 atributos dos 1003 extraídos, sendo 103 de EEG, 103 de voz, idade, gênero e diagnóstico. Já o PSO selecionou 204 atributos como mais relevantes: 109 de EEG, 92 de voz, idade, gênero e diagnóstico. Ambos os métodos selecionaram cerca de 20% da quantidade original de atributos, representando uma redução significativa na dimensionalidade dos conjuntos.

CAPÍTULO 5

5. RESULTADOS E DISCUSSÕES

Neste capítulo são apresentados os resultados dos experimentos utilizando os métodos que foram descritos no capítulo anterior, nas etapas de classificação, análise dos métodos e a seleção de atributos. Como também, as discussões dos principais resultados encontrados, através dos procedimentos utilizados. São apresentados também os resultados de teste do modelo com melhor desempenho dentre os avaliados na etapa de treinamento.

5.1 EXPERÊNCIA DA COLETA

Foi contemplado o primeiro objetivo específico, que trata da coleta de dados para a construção da base de dados própria. Foram ainda realizadas revisões da literatura acerca dos conceitos que norteiam o estudo, além de testes computacionais preliminares com bases de dados públicas, os quais resultaram em participações em publicações científicas na forma de artigos para eventos e capítulos de livro.

Quanto à coleta dos dados, a aplicação do protocolo tem duração de cerca de 1h30, podendo variar de acordo com a participação dos voluntários nos relatos associados às suas histórias de vida (relatos autobiográficos). No geral, o protocolo foi de fácil aplicação e fluiu bem, não tendo sido observados sinais de desgaste para participantes. Vale mencionar que a base de dados proveniente desse estudo consiste em uma importante contribuição para a literatura, já que existem poucas bases de dados relacionadas a emoções no contexto de idosos, especialmente quando se trata de pessoas com algum comprometimento neurológico como demências.

5.2 RESULTADOS DOS EXPERIMENTOS

Inicialmente, foi realizada uma validação cruzada com 10 *folds*, repetida 30 vezes, para obter uma estimativa mais precisa do desempenho dos classificadores. Os resultados obtidos utilizando todos os atributos estão apresentados na Tabela 1. Com base nesses resultados, o Random Forest com 200 árvores foi escolhido como o modelo mais adequado, pois apresentou os melhores valores para o conjunto de métricas de avaliação, com acurácia de $99,803 \pm 0,093$, índice kappa de $0,997 \pm 0,001$, sensibilidade de $0,998 \pm 0,003$, especificidade de $0,998 \pm 0,003$ e área sob a curva ROC (AUC) de $0,999 \pm 0,000$ para a base de dados sem seleção de atributos.

Tabela 1: Resultado da validação cruzada para os métodos de classificação Bayes Net, Naive Bayes, árvore de decisão J48, Random Tree e Random Forest (100, 200, 300, 400 e 450 árvores), sem seleção de atributos.

Classificador	Acurácia (%)		Índice Kappa		Sensibilidade		Especificidade		Área ROC	
	Média	Desvio Padrão	Média	Desvio Padrão	Média	Desvio Padrão	Média	Desvio Padrão	Média	Desvio Padrão
Bayes Net	92,044	0,844	0,880666	0,013	0,937	0,011	0,930	0,007	0,984	0,001
Naive Bayes	0,000	0,000	1,000	0,000	0,000	0,000	0,000	0,000	0,005	0,000
J48	98,290	0,559	0,974	0,008	0,988	0,005	0,987	0,007	0,991	0,003
Random Tree	88,429	0,011	0,826	0,000	0,881	0,017	0,910	0,004	0,896	0,010
RF 100	99,671	0,093	0,995	0,001	0,998	0,003	0,998	0,003	0,999	0,000
RF 200	99,803	0,093	0,997	0,001	0,998	0,003	0,999	0,001	0,999	0,000
RF 300	99,737	0,000	0,996	0,000	0,998	0,003	0,999	0,001	1,000	0,000
RF 400	99,737	0,000	0,996	0,000	0,998	0,003	0,999	0,001	1,000	0,000
RF 450	99,737	0,000	0,996	0,000	0,998	0,003	0,999	0,001	1,000	0,000

Fonte: A Autora (2024)

Após esta etapa, foram realizados experimentos para avaliar a eficácia de métodos de seleção de atributos Algoritmos Genéticos (AG) e Otimização por Enxame de Partículas (PSO). Os resultados obtidos com a aplicação de AG e PSO foram comparados com aqueles sem qualquer seleção de atributos. Para garantir a robustez dos resultados, os testes foram realizados no módulo Experimenter, utilizando a técnica de validação cruzada com 10 *folds*. Cada experimento foi repetido 30 vezes, gerando um total de 300 execuções para cada classificador utilizando as bases de dados provenientes de cada método de seleção de atributos. Este procedimento foi replicado para cada um dos métodos de classificação avaliados previamente: Bayes Net, Naive Bayes, árvore de decisão J48, Random Tree e Random Forest (com variações de 100, 200, 300, 400 e 450 árvores).

Para facilitar a análise dos dados obtidos, foi realizada uma redução estatística dos resultados, mantendo os valores de média e desvio padrão das métricas de desempenho. Os resultados são apresentados nas Tabelas 2 e 3, a partir dos quais é possível traçar uma comparação entre o desempenho dos classificadores frente aos atributos selecionados por

cada método avaliado. A análise das médias e desvios padrão das métricas permite identificar quais métodos de seleção e quais classificadores apresentam os melhores resultados.

Com base nos resultados apresentados na Tabela 2, que detalha os desempenhos do subconjunto de atributos selecionado com AG, o modelo Random Forest com 100 árvores foi escolhido. Esse modelo se destacou ao apresentar os melhores resultados em todas as métricas de avaliação: acurácia (99,737±0,185), índice kappa (0,994±0,003), sensibilidade (1,000±0,000), especificidade (0,996±0,003) e AUC (0,999±0,000). Embora os modelos Random Forest com 200, 300, 400 e 450 árvores tenham mostrado desempenhos semelhantes, com valores praticamente equivalentes nessas métricas, a versão com 100 árvores foi preferida devido à sua eficiência computacional. Este modelo oferece um equilíbrio ideal entre precisão e complexidade, tornando-o a opção mais eficaz para o conjunto de dados e o processo de seleção de atributos realizado.

Tabela 2: Valores de média, o desvio padrão das métricas de acurácia, kappa, sensibilidade, especificidade e área da curva ROC da base de dados com seleção de atributos por AG para os métodos de classificação Bayes Net, Naive Bayes, árvore de decisão J48, Random Tree e Random Forest (100, 200, 300, 400 e 450 árvores).

<u>Seletor (AG)</u>	Acurácia (%)		Índice Kappa		Sensibilidade		Especificidade		Área ROC	
	Média	Desvio Padrão	Média	Desvio Padrão	Média	Desvio Padrão	Média	Desvio Padrão	Média	Desvio Padrão
Bayes Net	91,978	1,123	0,8796	0,017	0,933	0,033	0,953	0,000	0,988	0,005
Naive Bayes	71,334	2,072	0,570	0,031	0,925	0,000	0,672	0,007	0,902	0,009
J48	98,948	0,185	0,984	0,003	0,990	0,003	0,989	0,004	0,993	0,000
Random Tree	90,533	0,549	0,858	0,008	0,881	0,011	0,929	0,011	0,905	0,000
RF 100	99,737	0,185	0,994	0,003	1,000	0,000	0,996	0,003	0,999	0,000
RF 200	99,737	0,186	0,996	0,003	1,000	0,000	0,997	0,004	0,999	0,000
RF 300	99,737	0,186	0,996	0,003	1,000	0,000	0,997	0,004	0,999	0,000
RF 400	99,737	0,186	0,996	0,003	1,000	0,000	0,997	0,004	0,999	0,000
RF 450	99,737	0,186	0,996	0,003	1,000	0,000	0,997	0,004	0,999	0,000

Fonte: A Autora (2024)

De acordo com os dados apresentados na Tabela 3, o PSO foi identificado como o método de seleção de atributos mais eficaz. Ele permitiu que o modelo Random Forest com 300 árvores alcançasse resultados médios altamente significativos em várias métricas: acurácia ($99,868 \pm 0,000$), índice kappa ($99,868 \pm 0,000$), sensibilidade ($1,000 \pm 0,000$), especificidade ($0,999 \pm 0,001$) e área sob a curva ROC ($1,000 \pm 0,000$). Embora esses resultados sejam superiores aos obtidos com Algoritmos Genéticos (AG) e sem a seleção de atributos, eles indicam que tanto Otimização por Enxame de Partículas (PSO) quanto AG são eficazes na seleção dos atributos mais relevantes. No entanto, vale destacar que, apesar de os ganhos em desempenho não serem drasticamente superiores à abordagem sem seleção de atributos, a seleção ainda é benéfica. Ela contribui para reduzir a complexidade dos classificadores e torna o processo de treinamento mais eficiente. Após a seleção, o número de atributos foi reduzido de 1003 quando todos os atributos foram considerados, para 209 atributos com AG, e 204 atributos com PSO.

Tabela 3: Valores de média, o desvio padrão das métricas de acurácia, kappa, sensibilidade, especificidade e área da curva ROC da base de dados com seleção de atributos por PSO para os métodos de classificação Bayes Net, Naive Bayes, árvore J48, Random Tree e Random Forest (100, 200, 300, 400 e 450 árvores).

<u>Seletor (PSO)</u>	Acurácia (%)		Índice Kappa		Sensibilidade		Especificidade		Área ROC	
	Média	Desvio Padrão	Média	Desvio Padrão	Média	Desvio Padrão	Média	Desvio Padrão	Média	Desvio Padrão
Classificador										
Bayes Net	90,203	1,032	0,853	0,015	0,933	0,017	0,956	0,001	0,987	0,002
Naive Bayes	74,752	2,069	0,621	0,031	0,838	0,005	0,789	0,022	0,880	0,002
J48	98,488	0,466	0,977	0,007	0,984	0,011	0,987	0,001	0,989	0,007
Random Tree	90,926	1,682	0,864	0,025	0,903	0,031	0,933	0,008	0,918	0,019
RF 100	99,737	0,186	0,996	0,003	1,000	0,000	0,996	0,003	0,999	0,000
RF 200	99,803	0,093	0,997	0,001	1,000	0,000	0,998	0,003	1,000	0,000
RF 300	99,868	0,000	99,868	0,000	1,000	0,000	0,999	0,001	1,000	0,000
RF 400	99,803	0,093	0,997	0,001	1,000	0,000	0,998	0,003	1,000	0,000
RF 450	99,803	0,093	0,997	0,001	1,000	0,000	0,998	0,003	0,999	0,000

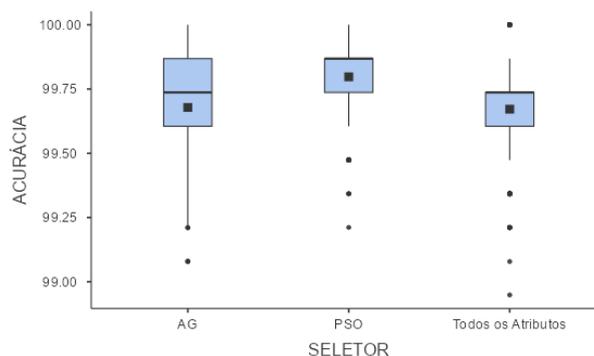
Fonte: A Autora (2024)

As Figuras 7-11 apresentam diagramas de caixa (*boxplots*) que ilustram as distribuições dos resultados das melhores classificações obtidas em três contextos:

utilizando todos os atributos, utilizando os subconjuntos de atributos selecionados por Algoritmos Genéticos (AG), e utilizando os subconjuntos selecionados por Otimização por Enxame de Partículas (PSO). Esses gráficos permitem uma visualização clara das medianas, dos quartis, e da dispersão dos dados, facilitando a comparação do desempenho entre os diferentes métodos de seleção de atributos e a classificação sem seleção.

Considerando os valores das métricas apresentados anteriormente, o método Random Forest apresentou resultados mais próximos dos valores máximos para cada uma delas em todas as bases avaliadas (com todos os atributos, com atributos selecionados por AG e selecionados por PSO). Na Figura 7 é possível observar o diagrama de caixa da métrica de acurácia, que permite observar a distribuição dessa métrica para os modelos com melhor desempenho em cada base. Esse gráfico mostra não apenas a mediana da acurácia obtida pelo modelo, mas também os quartis e possíveis pontos fora da curva, fornecendo uma visão detalhada da variabilidade dos desempenhos dos classificadores com melhor performance. No gráfico é possível observar que os resultados são estatisticamente semelhantes, embora a dispersão tenha sido maior para a base com atributos extraídos por AG e a média tenha sido superior para a base com atributos selecionados por PSO, esta última também apresentou menos pontos fora da curva.

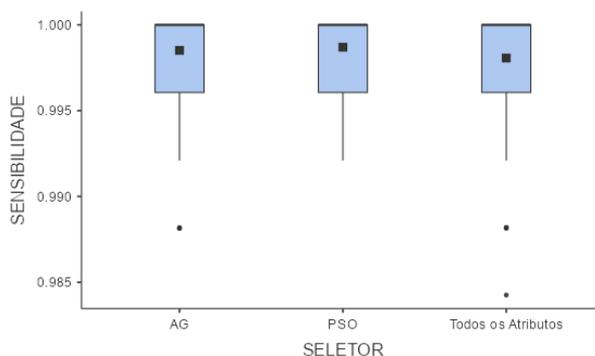
Figura 7 – Diagrama de caixa (*boxplot*) da acurácia do classificador Random Forest, o algoritmo com melhor desempenho para os conjuntos avaliados.



Fonte: A autora (2024)

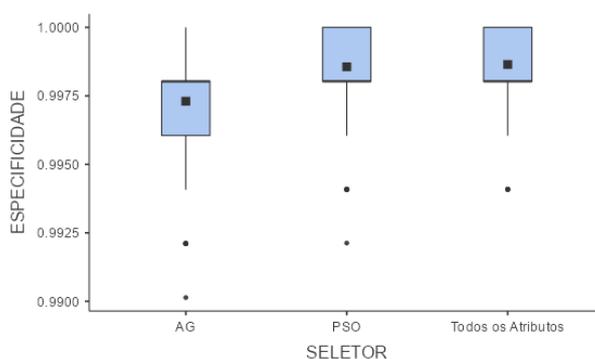
Na Figura 8, é apresentado o *boxplot* da sensibilidade. Este diagrama ajuda a visualizar a variabilidade e a mediana da sensibilidade do melhor modelo para cada base, onde é possível observar que todas demonstraram desempenho estatisticamente semelhantes, com a média levemente menor para a base com todos os atributos, a qual apresentou ou pouco mais de pontos fora da curva em relação às outras. De maneira semelhante, na Figura 9 está o *boxplot* da especificidade, evidenciando a capacidade do modelo de classificar corretamente os resultados negativos.

Figura 8 – Diagrama de caixa (*boxplot*) da sensibilidade do classificador Random Forest, o algoritmo com melhor desempenho para os conjuntos avaliados.



Fonte: A autora (2024)

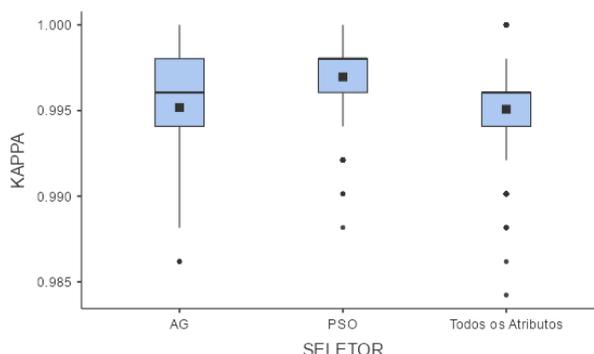
Figura 9 – Diagrama de caixa (*boxplot*) da especificidade do classificador Random Forest, o algoritmo com melhor desempenho para os conjuntos avaliados.



Fonte: A autora (2024)

Na Figura 10, é apresentado o *boxplot* do índice kappa, que ilustra a concordância entre as previsões do modelo e os valores reais. O índice kappa é particularmente útil para avaliar a robustez das previsões em situações onde as classes podem estar desbalanceadas. O diagrama de caixa da Figura 10 revela que os seletores de atributos AG e PSO exibiram comportamentos bastante similares no que diz respeito ao índice kappa. Isso sugere que ambos os métodos de seleção de atributos alcançaram níveis comparáveis de concordância entre as previsões dos modelos e os valores reais. Portanto, ambos os métodos mostraram eficácia semelhante em melhorar a consistência das previsões do modelo.

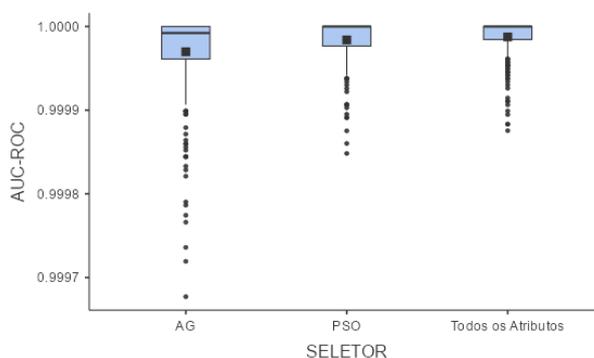
Figura 10 – Diagrama de caixa (*boxplot*) do índice kappa do classificador Random Forest, o algoritmo com melhor desempenho para os conjuntos avaliados.



Fonte: A Autora (2024)

A Figura 11 revela que o método Random Forest apresentou uma distribuição dos dados significativa em relação à métrica área sob a curva ROC. O diagrama de caixa também indica que o classificador teve uma distribuição uniforme dos valores de acurácia e índice kappa. Isso sugere que o Random Forest não apenas demonstrou um desempenho consistente na capacidade de discriminação entre as classes, como evidenciado pela área sob a curva ROC, mas também manteve uma performance estável em termos de acurácia e concordância entre previsões e valores reais.

Figura 11 – Diagrama de caixa (*boxplot*) da AUC-ROC do Classificador Random Forest, o algoritmo com melhor desempenho para os conjuntos avaliados.



Fonte: A Autora (2024)

Como já foi observado, o Random Forest apresenta comportamentos semelhantes para as bases de dados, considerando todas as métricas. No entanto, a visualização proporcionada pelos *boxplots* reforçam a superioridade do seletor PSO em relação às demais configurações, exibindo uma maior uniformidade e proximidade aos valores ideais, refletindo um desempenho mais consistente e otimizado em comparação com o método de seleção de atributos AG e a base de dados com todos os atributos extraídos.

Por fim, com o intuito de observar a capacidade de generalização dos modelos treinados, eles foram aplicados às bases de teste criadas, cujos resultados estão na Tabela 4, onde é possível observar excelentes desempenhos de classificação para todas as bases

de teste, todas alcançando os valores máximos. Vale salientar que os dados que compõem esta base de teste não fizeram parte do treinamento, portanto, são dados novos para o modelo.

Tabela 4: Resultados para as bases de teste de todos os atributos para o método de classificação Random Forest de 200 árvores, do seletor de atributos AG para o método de classificação Random Forest de 100 árvores, do seletor de atributos PSO para o método de classificação Random Forest de 300 árvores.

Base	Classificador	Acurácia	Kappa	Sensibilidade	Especificidade	AUC
Todos os atributos	RF 200	100%	1,000	1,000	1,000	1,000
AG	RF 100	100%	1,000	1,000	1,000	1,000
PSO	RF 300	100%	1,000	1,000	1,000	1,000

Fonte: A Autora (2024)

Nas Tabelas 5-7 estão compiladas as matrizes de confusão dos melhores resultados de cada grupo. Cada tabela apresenta uma matriz de confusão que ajuda a visualizar o desempenho dos modelos de classificação. À esquerda de cada matriz, estão listadas as classes verdadeiras, representadas por letras para facilitar a identificação. Essas letras correspondem às classes originais dos dados. À direita, estão indicadas as classificações das instâncias, que mostram como as instâncias foram realmente classificadas pelos modelos. As células da matriz de confusão mostram o número de instâncias para cada combinação de classe verdadeira e classe predita, permitindo uma avaliação detalhada de como o modelo classificou cada classe e onde ocorreram erros. Para todos os conjuntos é possível observar que todas as 690 instâncias de cada base foram corretamente classificadas, confirmando os valores das métricas apresentadas na Tabela 4.

Tabela 5 – Matriz de confusão da classificação com todos os atributos utilizando o melhor classificador para essa base (Random Forest de 200 árvores).

Classe esperada Classe estimada	a	b	c
	Negativo	Neutro	Positivo
a = Negativo	44	0	0
b = Neutro	0	12	0
c = Positivo	0	0	634

Tabela 6 – Matriz de confusão da classificação com atributos selecionados com AG utilizando o melhor classificador para essa base (Random Forest de 100 árvores).

Classe esperada Classe estimada	a	b	c
	Negativo	Neutro	Positivo
a = Negativo	44	0	0
b = Neutro	0	12	0
c = Positivo	0	0	634

Tabela 7 – Matriz de confusão da classificação com atributos selecionados com PSO utilizando o melhor classificador para essa base (Random Forest de 300 árvores).

Classe esperada Classe estimada	a	b	c
	Negativo	Neutro	Positivo
a = Negativo	44	0	0
b = Neutro	0	12	0
c = Positivo	0	0	634

Considerando todos os resultados apresentados, observa-se que após a redução dos atributos não houve redução no desempenho de classificação das instâncias em comparação com os testes realizados utilizando todos os atributos. Mais ainda, houve leve melhora para o conjunto com os atributos selecionados por PSO. É importante lembrar que para ambos os métodos de seleção houve uma redução significativa da quantidade de atributos em cerca de 79%. Embora a quantidade de atributos selecionados seja muito menor do que a quantidade original de atributos extraídos, houve melhora no desempenho de classificação de emoções, isso sugere que há uma redundância nos atributos extraídos pela rede profunda LeNet e que a redução de atributos foi eficaz sem impactar negativamente o desempenho do modelo.

CAPÍTULO 6

6. CONCLUSÃO

6.1 CONCLUSÕES GERAIS

Esta dissertação de mestrado teve como objetivo geral desenvolver um modelo robusto e otimizado para o reconhecimento de emoções em idosos, utilizando sinais de EEG e voz, e também informações demográficas. Os resultados obtidos nesta pesquisa demonstram que o objetivo geral foi atingido. A base de dados coletada é uma das maiores e mais completas na área de reconhecimento de emoções em idosos até o momento, e o modelo desenvolvido apresentou um alto desempenho na classificação das emoções, com valores de acurácia superiores a 99%. A seleção de atributos utilizando PSO contribuiu para a redução da complexidade do modelo e para a melhoria do seu desempenho.

O modelo desenvolvido nesta dissertação tem potencial para ser aplicado em diferentes contextos, como no cuidado com idosos, na interação homem-máquina e na pesquisa científica. O uso do modelo pode auxiliar na identificação de alterações de humor em idosos, na avaliação do impacto de intervenções terapêuticas e no desenvolvimento de interfaces mais intuitivas e personalizadas para interação com essa população.

6.2 DIFICULDADES APRESENTADAS

O desenvolvimento desta pesquisa apresentou algumas dificuldades com relação à seleção de atributos:

- **Alta Dimensionalidade:** A grande quantidade de atributos extraídos dos sinais de EEG e voz poderia dificultar o aprendizado dos modelos de classificação e reduzindo seu desempenho.
- **Interpretabilidade:** A interpretação dos atributos selecionados e sua relação com as emoções foi complexa e exigiu análises adicionais para compreender os padrões subjacentes.

Com relação à classificação de emoções, as principais dificuldades foram:

- **Escolher o Algoritmo Adequado:** Selecionar o algoritmo de classificação mais adequado para a tarefa específica de reconhecimento de emoções em idosos foi um desafio, considerando a natureza complexa das emoções, a variabilidade individual, e a dificuldade inicial em se entender as estatísticas e gráficos adotados na pesquisa.

- **Treinamento e Otimização do Modelo:** Treinar e otimizar os parâmetros do modelo de classificação para alcançar o melhor desempenho possível poderia ser um processo iterativo e exigir ajustes finos para lidar com a variabilidade dos dados. Por essa razão, adotamos algoritmos que usam poucos parâmetros ou até mesmo nenhum parâmetro mas que mesmo assim poderiam obter bons resultados.
- **Generalização do Modelo:** Garantir que o modelo de classificação aprendido generalize bem para novos dados não utilizados no treinamento e seja capaz de identificar emoções com precisão em diferentes contextos é um dos maiores desafios de toda aplicação que envolve inteligência artificial e aprendizado de máquina.

Com relação especificamente à análise e interpretação dos resultados, as maiores dificuldades se traduziram nos seguintes pontos:

- **Avaliação Multifacetada:** Avaliar o desempenho do modelo de classificação utilizando diversas métricas e abordagens, como análise estatística, visualização de dados e interpretação de resultados, é essencial para uma avaliação completa, mas também é muito difícil de se fazer, principalmente quando se vem de áreas de formação onde o uso da estatística não é tão intensivo.
- **Considerações Contextuais:** Considerar o contexto das emoções dos idosos, como a situação em que foram coletadas e as características individuais dos participantes é fundamental para uma interpretação mais profunda dos resultados.
- **Limitações e Generalizações:** Identificar as limitações da pesquisa, como o tamanho da amostra e as características dos participantes, e discutir a generalização dos resultados para outras populações seria importante para a confiabilidade e aplicabilidade das descobertas. Esta pesquisa teve como limitante um baixo número de participantes (39), embora tenha como principal vantagem ter produzido uma base de dados inédita no estudo da saúde mental da pessoa idosa.

6.3 CONTRIBUIÇÕES E TRABALHOS FUTUROS

As principais contribuições desta pesquisa podem ser resumidas nos seguintes pontos:

- Desenvolvimento de uma base de dados robusta para o reconhecimento de emoções em idosos.
- Proposição de um modelo de classificação de emoções com alto desempenho.
- Demonstração da eficácia da seleção de atributos para o reconhecimento de emoções em idosos.

- Ampliação do conhecimento sobre as características das emoções em idosos, com e sem demência.

Os resultados parciais desta pesquisa foram comunicados na publicação em resumo estendido “Expressão de emoções em idosos com e sem demência: uma abordagem para aquisição de dados de diferentes modalidades”, no VII Simpósio de Inovação em Engenharia Biomédica - SABIO 2023, realizado em Recife, na Universidade Federal de Pernambuco, em 2023 (Santos et al., 2023).

Os resultados desta dissertação de mestrado representam um passo importante no desenvolvimento de novas tecnologias para o reconhecimento de emoções em idosos. As ferramentas e os modelos desenvolvidos neste trabalho podem ser utilizados para aprimorar o cuidado com essa população, para promover a interação homem-máquina mais natural e para aprofundar o conhecimento sobre as emoções humanas no contexto do envelhecimento.

Como trabalhos futuros, pretendemos reavaliar o protocolo de aquisição para ampliar a base de dados, realizando mais coletas. Também pretendemos investir na construção de um modelo de aprendizado de máquina capaz de construir automaticamente sugestões de diagnóstico de demências, investigando: outros modelos de redes neurais profundas que possam melhor representar os sinais de EEG e de voz, diferentes do LeNet; outros classificadores que não a Random Forest, em especial modelos de redes profundas e também modelos rápidos e rasos; e outros métodos de seleção de atributos, visando contribuir para a construção de uma ferramenta útil para o apoio ao diagnóstico e às abordagens terapêuticas da doença de Alzheimer e das demências no geral.

REFERÊNCIAS

- [1] ABRAZ (Associação Brasileira de Alzheimer) 2014.
- [2] ABRISQUETA-GOMEZ, J.; SANTOS, F. H. Reabilitação Neuropsicológica: da teoria à prática. São Paulo: Artes Médicas, 2006.
- [3] Ahmed, O. B., Pineal, J. B., Allard, M., Catheline, G. & Amar, C. B. (2016). Recognition of Alzheimer's Disease and Mild Cognitive Impairment with multimodal image-derived biomarkers and Multiple Kernel Learning. *Computerized Medical Imaging and Graphics*, 16 (1), 1-35.
- [4] Almeida, Osvaldo P. Mini exame do estado mental e o diagnóstico de demência no Brasil. *Arquivos de Neuro-psiquiatria*, v. 56, p. 605-612, 1998.
- [5] Alzheimer's Association. Alzheimer's Disease Facts and Figures. Includes a Special Report on Alzheimer's Detection in the Primary Care Setting: Connecting Patients and Physicians 2019;15(3):321-87.
- [6] ALZHEIMER'S DISEASE INTERNATIONAL. World Alzheimer Report 2021: Journey through the diagnosis of dementia. Disponível em: <https://www.alzint.org/resource/world-alzheimer-report-2021/>. Acesso em: 23 jan. 2024.
- [7] ANDERSEN, P. A. & GUERRERO, L. K. (eds.) (1998). *Handbook of Communication and Emotion: Research, Theory, Applications, and Contexts*. San Diego: Academic Press.
- [8] Aprahamian, I., Martinelli, J. E., e Yassuda, M. S. (2009). Doença de Alzheimer: revisão da epidemiologia e diagnóstico. *Rev Bras Clin Med*, 7(6):27–35.
- [9] Aragão, R. F. et al. (2018). As manifestações clínicas e implicações no cotidiano do idoso com doença de Alzheimer. *Revista Interdisciplinar em Saúde*, 5 (2), 198-207.
- [10] Atkinson, J. e Campos, D. (2016). Improving BCI-based emotion recognition by combining EEG feature selection and kernel classifiers. *Expert Systems with Applications*, 47:35–41.
- [11] AVERILL, J. A semantic atlas of emotion concepts. American Psychological Association, 1975.
- [12] AZEVEDO, W.W. et al. Inteligência Artificial Para o Apoio ao Diagnóstico da Doença de Alzheimer utilizando Imagens de Ressonância Magnética. 2019.
- [13] Barbosa, P. S., & Cotta, M. (2017). Psicologia e musicoterapia no tratamento de idosos com demência de Alzheimer. *Revista Brasileira de Ciências da Vida*, 5 (3), 1-23.

- [14] Barclay, L. Clinical Geriatric Neurology. Pennsylvania: Lea e Febiger, 1990.
- [15] BARRETT, L. F. Are emotions natural kinds? Perspectives on Psychological Science, Sage, 2006.
- [16] BARRETT, L. F. How Emotions Are Made: The Secret Life of the Brain. Houghton Mifflin Harcourt, 2017.
- [17] Caetano, L. A.O., Silva, F.S. & Silveira, C. A. B. (2017). Alzheimer, sintomas e grupos: uma revisão integrativa. *Vínculo - Revista do NESME*, 14(2), 84-93.
- [18] CAIXETA, L. et al. Doença de Alzheimer. Porto Alegre: Artmed, 2012.
- [19] Cambria, E. (2016). Affective computing and sentiment analysis. *IEEE Intelligent Systems*, 31(2):102–107.
- [20] Carlson, T. e Millan, J. d. R. (2013). Brain-controlled wheelchairs: a robotic architecture. *IEEE Robotics & Automation Magazine*, 20(1):65–73.
- [21] Cassel, C. et al. Geriatric Medicine. 2.ed. Nova Iorque: Springer, 1990.
- [22] CASCARANI, A. P. A ação da musicoterapia no tratamento da pessoa com doença de Alzheimer. In CAOVIOLA, V. P.; CANINEU, P. (Orgs). *Você não está sozinho... nós continuamos com você*. São Paulo: Novo Século, 2013.
- [23] CHARNIAK, Eugene; MCDERMOTT, Drew. A Bayesian Model of Plan Recognition. Massachusetts: Addison-Wesley, 1985.
- [24] COLLINS, A.; ORTONY, A.; CLORE, G. The Cognitive Structure of Emotions. Cambridge: Cambridge University Press, 1988.
- [25] Correia, Flavia. Inteligência Artificial pode detectar Alzheimer anos antes de aparecimento dos sintomas, dizem cientistas. **Olhar Digital**, 2021. Disponível em: <https://olhardigital.com.br/2021/08/13/medicina-e-saude/inteligencia-artificial-pode-detectar-alzheimer-anos-antes-dos-sintomas/>. Acesso em: 10 maio. 2022.
- [26] Cunha, Rosemyriam. Musicoterapia na abordagem do idoso. Universidade Tuiuti do Paraná, 1999. Monografia de especialização.
- [27] DAS, K.; BEHERA, R. N. A survey on machine learning: Concept, algorithms and applications. *International Journal of Innovative Research in Computer and Communication Engineering*, 2017.
- [28] Darwin, Charles. (2004). A expressão das emoções no homem e nos animais. São Paulo: Companhia das Letras.
- [29] Denham, S. A. (2007). Dealing with feelings: how children negotiate the worlds of emotions and social relationships. *Cognition, Brain, Behavior* 11, 1 – 48.

- [30] De Souza, M. C., da Rocha Alves, A. B., de Lima, D. S., de Oliveira, L. R. F. A., da Silva, J. K. B., de Oliveira Ribeiro, E. C., Lopes, M. E. S., Aureliano, A. S., da Silva, G. A., de Oliveira, I. D., et al. (2017). The treatment of Alzheimer in the context of musicotherapy. *International Archives of Medicine*, 10.
- [31] Ekman, P. *Facial Expressions. The Handbook of Cognition and Emotion*. John Wiley & Sons, Sussex, Reino Unido, 1999.
- [32] Ekman, P. (2011). *A linguagem das emoções* (C. Szlak, Trad.). São Paulo: Lua de Papel. (Obra original publicada 2003).
- [33] Engelhardt, E. et al. Tratamento da doença de Alzheimer: recomendações e sugestões do Departamento Científico de Neurologia Cognitiva e do Envelhecimento da Academia Brasileira de Neurologia. *Arq. Neuro-Psiquiatr.*, São Paulo, v. 63, n. 4, p. 1104-1112, Dec. 2005.
- [34] Escher, C., Jessen, F. Prevenção do declínio cognitivo e demência através do tratamento de fatores de risco. *Neurologista* **90**, 921–925 (2019). Disponível em: <<https://doi.org/10.1007/s00115-019-0759-6>>. Acesso em: 11 dezembro. 2023.
- [35] Fang, R., Ye, S., Huangfu, J., e Calimag, D. P. (2017). Music therapy is a potential intervention for cognition of Alzheimer’s disease: a mini-review. *Translational Neurodegeneration*, 6(1):2.
- [36] FASEL, B.; LUETTIN, J. Automatic facial expression analysis: a survey. *Pattern Recognition*, v. 36, p. 259-275, 2003.
- [37] Fernandes, J. S. G. & Andrade, M. S. (2017) Revisão da literatura acerca da conduta terapêutica na doença de Alzheimer: diagnóstico, evolução e cuidados. *Psicologia, saúde e doenças*. 18 (1), 131-139.
- [38] FERNÁNDEZ, Alberto et al. SMOTE for learning from imbalanced data: progress and challenges, marking the 15-year anniversary. *Journal of artificial intelligence research*, v. 61, p. 863-905, 2018.
- [39] Fridman, Cintia; Gregório, Sheila; Neto, Emmanuel Dias; Ojopi, Élide P. Benquique. Alterações genéticas na doença de Alzheimer. *Rev. Psiq. Clín.* V. 31, n.1, p. 19-25, 2004.
- [40] Gallego, M. G. e Garcia, J. G. (2017). Music therapy and Alzheimer’s disease: Cognitive, psychological, and behavioural effects. *Neurología (English Edition)*, 32(5):300–308.
- [41] Gimenes, F. F. (2019). Um probleminha de memória, um probleminha de cabeça, um probleminha de esquecimento: as estratégias referenciais em narrativas de um grupo de apoio. [*Mestrado em linguística aplicada*].
- [42] Goleman, D. (1995). *Inteligência emocional*. Lisboa: Temas e Debates.

- [43] Halberstadt, A., Denham, S., & Dunsmore, J. (2001). Affective Social Competence. *Social Development*, 10 (1), 79-119.
- [44] Haugeland, John. *Artificial Intelligence: The Very Idea*. Massachusetts: The MIT Press, 1985.
- [45] HELM, J. M. et al. *Machine learning and artificial intelligence: Definitions, applications, and future directions*. Springer Science, 2020.
- [46] <https://focusfoto.com.br/camera-canon-t7-e-boa/>
- [47] Huang, Juebin. Doença de Alzheimer. **Manual MSD – Versão para Profissionais de Saúde**, 2023. Disponível em: <https://www.msdmanuals.com/pt/casa/distúrbios-cerebrais,-da-medula-espinal-e-dos-nervos/delirium-e-demência/doença-de-alzheimer>. Acesso em: 10 maio. 2023.
- [48] IBGE. **Censo Demográfico 2010**. Brasília, 2011. Disponível em: http://www.ibge.gov.br/home/estatistica/populacao/censo2010/default_sinopse.shtm. Acesso em: 10 de agosto de 2024.
- [49] Izard, C. E. (2009). Emotion Theory and Research: Highlights, Unanswered Questions and Emerging Issues. *Annu Rev Psychol.* 60, 1-25.
- [50] Jaques, P. A., & Vicari, R. Considering Student's Emotions in Computer Mediated Learning Environments. In: Z. Ma (Ed). *Web-based Intelligent e Learning Systems: Technologies and Applications* (pp.122-138). Hershey, PA: Information Science Publishing. 2005.
- [51] King, J., Jones, K., Goldberg, E., Rollins, M., MacNamee, K., Moffit, C., Naidu, S., Ferguson, M., Garcia Leavitt, E., Amaro, J., et al. (2019). Increased functional connectivity after listening to favored music in adults with Alzheimer dementia. *The Journal of Prevention of Alzheimer's Disease*, 6(1):56–62.
- [52] Kurzweil, Ray. *The Age of Spiritual Machines*. Massachusetts: The MIT Press, 1990.
- [53] Liu Y, Paajanen T, Zhang Y, Westman E, Wahlund LO, Simmons A, e o Iniciativa ADNI. Analysis of regional MRI volumes and thicknesses as predictors of conversion from mild cognitive impairment to Alzheimer's disease. *Neurobiol Aging*. 2018;71:169-176 2.
- [54] Li, Z., Qiu, L., Li, R., He, Z., Xiao, J., Liang, Y., Wang, F., e Pan, J. (2020). Enhancing BCI-based emotion recognition using an improved particle swarm optimization for feature selection. *Sensors*, 20(11):3028.

- [55] Machado, A. P. R., Carvalho, I. O. & Rocha Sobrinho, H. M. (2020). Neuroinflamação na doença de Alzheimer. *Revista Brasileira Militar de Ciências*, 6 (14), 30-38.
- [56] Magalhães, A. (2007). *A Psicologia das emoções: o Fascínio do Rosto Humano*. Porto: Edições Universidade Fernando Pessoa.
- [57] Magalhães, A. (2013). *O código de Ekman o cérebro, a face e a emoção*. Porto: Feelab Science Books.
- [58] Masumoto, Camila Kazue; Leal, Thalita Rodrigues; Leitão, Maria Teresa; Lago, Olival Cardoso. Exercício físico como recurso para prevenção de transtornos senis ocasionados pela perda neuronal. *Laboratório de pesquisa e ensino em biomecânica: Escola Superior de Educação Física de Jundiaí, Jundiaí, v. 2, n.3, p. 1-18, 2010.*
- [59] MELLO, J. T.; RODRIGUES, V. F. S. Intervenções nas alterações comportamentais e transtornos de humor na doença de Alzheimer. In: ABRISQUETA-GOMEZ, J. et al. *Reabilitação Neuropsicológica: Abordagem interdisciplinar e modelos conceituais na prática clínica*. São Paulo: Artmed, 2012.
- [60] MICHAELIS, Dicionário Brasileiro da Língua Portuguesa, Cia. Artificial. Melhoramentos, 2018. Disponível em: <<http://michaelis.uol.com.br/moderno-portugues/busca/portugues-brasileiro/artificial>>. Acesso em: 11 dezembro. 2023.
- [61] MICHAELIS, Dicionário Brasileiro da Língua Portuguesa, Cia. Inteligência. Melhoramentos, 2018. Disponível em: <<http://michaelis.uol.com.br/moderno-portugues/busca/portugues-brasileiro/intelig%C3%A2ncia>>. Acesso em: 11 dezembro. 2023.
- [62] Mohammadi, Z., Frounchi, J., e Amiri, M. (2017). Wavelet-based emotion recognition system using EEG signal. *Neural Computing and Applications*, 28(8):1985–1990.
- [63] MONTEIRO, L. C.; COVRE, P.; FUENTES, D. Reabilitação neuropsicológica. In: MALLOY-DINIZ, L. F; FUENTES, D.; COSENSA, R. M. (Orgs.). *Neuropsicologia do Envelhecimento: uma abordagem multidimensional*. Porto Alegre: Artmed, 2013.
- [64] Monteiro, W. H. M (2018). Doença de Alzheimer: aspectos fisiopatológicos. *Rev. Saberes*, 8 (2), 1-8.
- [65] Nitrini, R., Caramelli, P., Bottino, C., Damasceno, B. P., Brucki, S. M. D., e Anghinah, R. (2005a). Diagnóstico de doença de Alzheimer no Brasil: avaliação cognitiva e funcional. *Arq Neuropsiquiatria*, 63(3-A):720–727.

- [66] Nitrini, R., Caramelli, P., Bottino, C., Damasceno, B. P., Brucki, S. M. D., e Anghinah, R. (2005b). Diagnóstico de doença de Alzheimer no Brasil: critérios diagnósticos e exames complementares. *Arq Neuropsiquiatria*, 63(3-A):713–719.
- [67] Novak, D., Sigrist, R., Gerig, N. J., Wyss, D., Bauer, R., Götz, U., e Riener, R. (2018). Benchmarking braincomputer interfaces outside the laboratory: The cybathlon 2016. *Frontiers in neuroscience*, 11:756.
- [68] Organização Mundial da Saúde. (2019). Manual de treinamento e apoio para cuidadores de pessoas com demência.
- [69] Organização Mundial da Saúde. (2012) Demência: uma prioridade de saúde pública.
- [70] Palazzi, A. (2015). Musicoterapia na afasia de expressão: um estudo de caso. [Trabalho de Conclusão de Curso].
- [71] Parsons C. G., Danysz W., Dekundy A., Pulte I. Memantine and cholinesteraseinhibitors: complementary mechanisms in the treatment of Alzheimer's disease. *Neurotox Res*. 2013 Oct;24(3):358-69.
- [72] Picard, R.W. *Affective Computing*. MIT Press, Cambridge, EUA, 1997.
- [73] PINHO, T.A.M. et al. Avaliação do risco de quedas em idosos atendidos em Unidade Básica de Saúde. **Revista da Escola de Enfermagem**. USP [online], v.46, n.2, p. 320-327, 2014.
- [74] Poole, D.; MACKWORTH, A. K.; GOEBEL, R. *Computational Intelligence: A Logical Approach*. Oxford: Oxford University, 1998.
- [75] Poria, S., Cambria, E., Bajpai, R., e Hussain, A. (2017). A review of affective computing: From unimodal analysis to multimodal fusion. *Information Fusion*, 37:98–125.
- [76] Prado JÁ-L, Jiménez-Huete A. Neuroimagen en demencia. *Correlación clínico-radiológica*. *Radiología*. 2019;61(1):66-81.
- [77] Rios Filho, E. G. R et al. (2017). Alzheimer: fatores de risco associados ao seu desenvolvimento e sua manifestação. In *Resumos da XIII Mostra de saúde*. (p. 33) Goiânia, GO.
- [78] Rosado, P. S. V. (2016). Na senda da neuroplasticidade: musicoterapia aplicada à reabilitação neurológica. [Dissertação de Mestrado].
- [79] Russel, Stuart; NORVIG, Peter. *Inteligência Artificial*. 2. Ed. Rio de Janeiro: Campos, 2004.
- [80] Russel S, Norvig P. *Inteligência Artificial*. 3ª ed. Elsevier; 2013.

- [81] SACHARIN, V.; SCHLEGEL, K. & SCHERER, K. R. (2012). Geneva Emotion Wheel rating study (Report). Geneva, Switzerland: University of Geneva, Swiss Center for Affective Sciences.
- [82] SALES A, et al. **Conhecimento da equipe de enfermagem quanto aos cuidados com idoso portador da doença de Alzheimer**. R Enfer. Cent. O. Min. 2011 out/dez; 1(4):492-502.
- [83] Sampaio, R.T., Loureiro, C. M. V. & Gomes, C.M.A. (2015). A Musicoterapia e o Transtorno do Espectro do Autismo: uma abordagem informada pelas neurociências para a prática clínica. *Per musi*, 37 (1), 137-170.
- [84] SANEI, S.; CHAMBERS, J. EEG SIGNAL PROCESSING. [S.l.]: John Wiley & Sons Ltd, 2007.
- [85] SANTOS, W. O.; SANTANA, M. A. ; TORCATE, A. S. ; GOMES, J. C. ; MORENO, G. M. M. ; SANTOS, W. P. . Expressão de emoções em idosos com e sem demência: uma abordagem para aquisição de dados de diferentes modalidades. In: VII Simpósio de Inovação em Engenharia Biomédica, 2023, Recife. Anais do VII Simpósio de Inovação em Engenharia Biomédica - SABIO 2023. Recife: Universidade Federal de Pernambuco, 2023. v. 2023. p. 19-22.
- [86] SAYEG, N. Alzheimer: diagnóstico e tratamento. São Paulo: Yendis, 2009.
- [87] SCHERER, K. R. (2005). What are emotions? And how can they be measured?. *Social Science Information*. 44(4):693-727.
- [88] Sereniki, Adriana; Vital, Maria Aparecida Barbatto Frazão. A doença de Alzheimer: aspectos fisiopatológicos e farmacológicos. *Rev. Psiquiatria, Rio Grande do Sul*, vol.30, n.1, p. 1-17, 2008.
- [89] SERENIKI A, Vital M. **A doença de Alzheimer**: aspectos fisiopatológicos e farmacológicos. *Rev. Psiquiati RS*. 2008;301 (1 Supl).
- [90] Silva, C. (2011). Estudo de competências emocionais e sua correlação com o auto-conceito. Dissertação de mestrado, Universidade Fernando Pessoa, Porto.
- [91] Silva Souza M, Nery SBM, Araújo SM, Araújo P da C, Sousa AMC, Silva Élide B da, Nascimento IG do, Braga EM de S, Prado TM, Mano S de S, Nunes GF, Moura A de J, Freitas R de C. Uso Da Inteligência Artificial No Diagnóstico De Doenças Neurodegenerativas: Uma Revisão Integrativa. *Recisatec [Internet]*. 10º de outubro de 2022 [citado 2º de novembro de 2023];2(10):e210196. Disponível em:<https://recisatec.com.br/index.php/recisatec/article/view/196>.
- [92] SIQUEIRA F.V., FACCHINI L. A., DA SILVEIRA D. S., PICCINI R. X., TOMASI E. THUMÉ E., Prevalence of falls in elderly in Brazil: a countrywide analysis. **Caderno de Saúde Pública**. v. 27, n. 9., set., 2011.

- [93] Song, T., Zheng, W., Song, P., e Cui, Z. (2018). EEG emotion recognition using dynamical graph convolutional neural networks. *IEEE Transactions on Affective Computing*.
- [94] Spezzia, S. (2018). Saúde bucal e doença de Alzheimer. *Revista da Faculdade de Ciências Médicas de Sorocaba*, 20 (4), 191-194.
- [95] Subasi, A., Tuncer, T., Dogan, S., Tanko, D., e Sakoglu, U. (2021). EEG-based emotion recognition using tunable Q wavelet transform and rotation forest ensemble classifier. *Biomedical Signal Processing and Control*, 68:102648.
- [96] Torcate, A. S. et al. (2020). Intervenções e Impactos da Musicoterapia no Contexto da Doença de Alzheimer: Uma Revisão de Literatura sob a Perspectiva da Computação Afetiva. In *Anais do IV Simpósio de Inovação em Engenharia Biomédica – SABIO* (p.31). Recife, PE.
- [97] Torres, E. P., Torres, E. A., Hernández-Álvarez, M., e Yoo, S. G. (2020). EEG-based BCI emotion recognition: A survey. *Sensors*, 20(18):5083.
- [98] Vargas, Herber Soares. *Psicologia do envelhecimento*. São Paulo: Byk-Prociencx, 1983.
- [99] Vaz, F. J. (2009). *Diferenciação e Regulação Emocional na Idade Adulta: Tradução e Validação de Dois Instrumentos de Avaliação para a População Portuguesa*. Dissertação de Mestrado, Instituto de Educação e Psicologia - Universidade do Minho, Braga.
- [100] Ventura, A. L. M. et al. Sistema colinérgico: revisitando receptores, regulação e a relação com a doença de Alzheimer, esquizofrenia, epilepsia e tabagismo. *Rev. psiquiatr. clín.*, São Paulo, v. 37, n. 2, p. 66-72, 2010.
- [101] Vieira, M. M. C. D. S. (2020). *A doença de Alzheimer e a perda de Olfato* (Doctoral dissertation).
- [102] VIEIRA, R. T.; Epidemiologia da doença de Alzheimer. In _____. et al. *Doença de Alzheimer*. Porto Alegre: Artmed, 2012.
- [103] Westman, E., Muehlboeck, J. S. & Simmons, A. (2012). Combining MRI and CSF measures for classification of Alzheimer's disease and prediction of mild cognitive impairment conversion. *Neuroimage*, 62 (1), 229-238.
- [104] Woyciekoski, C. & Hutz, C. (2009). *Inteligência Emocional: Teoria, Pesquisa, Medida, Aplicações e Controvérsias*. *Psicologia: Ciência e Crítica*, 22 (1), 1-11.
- [105] Wu, C.-H., Huang, Y.-M., e Hwang, J.-P. (2016). Review of affective computing in education/learning: Trends and challenges. *British Journal of Educational Technology*, 47(6):1304–1323.

[106] Xia, P., Chen, H. S., Zhang, D., Lipton S. A. Memantine preferentially blocks extrasynaptic over synaptic NMDA receptor currents in hippocampal autapses. *Journal of Neuroscience*. 2010 Aug 18;30(33):11246-50.

[107] Zheng, W.-L. e Lu, B.-L. (2015). Investigating critical frequency bands and channels for eeg-based emotion recognition with deep neural networks. *IEEE Transactions on Autonomous Mental Development*, 7(3):162– 175.