

UNIVERSIDADE FEDERAL FLUMINENSE

LEONARDO LUÍS DA SILVA NARDI

**Identificação de Padrões de Interação no Treinamento
Cognitivo Computadorizado com Idosos**

NITERÓI

2018

UNIVERSIDADE FEDERAL FLUMINENSE

LEONARDO LUÍS DA SILVA NARDI

Identificação de Padrões de Interação no Treinamento Cognitivo Computadorizado com Idosos

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Computação da Universidade Federal Fluminense como requisito parcial para a obtenção do Grau de Mestre em Computação. Área de concentração: Computação Visual

Orientador:

DANIELA GORSKI TREVISAN

NITERÓI

2018

Ficha catalográfica automática - SDC/BEE
Gerada com informações fornecidas pelo autor

N223i Nardi, Leonardo Luís da Silva
Identificação de Padrões de Interação no Treinamento
Cognitivo Computadorizado com Idosos / Leonardo Luís da Silva
Nardi ; Daniela Gorski Trevisan, orientador. Niterói, 2018.
124 f. : il.

Dissertação (mestrado)-Universidade Federal Fluminense,
Niterói, 2018.

DOI: <http://dx.doi.org/10.22409/PGC.2018.m.07686599736>

1. Jogos cognitivos computadorizados. 2. Idosos. 3.
Mineração de dados. 4. Proveniência. 5. Produção
intelectual. I. Trevisan, Daniela Gorski, orientador. II.
Universidade Federal Fluminense. Escola de Engenharia. III.
Título.

CDD -

LEONARDO LUÍS DA SILVA NARDI

Identificação de Padrões de Interação no Treinamento Cognitivo Computadorizado com Idosos

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Computação da Universidade Federal Fluminense como requisito parcial para a obtenção do Grau de Mestre em Computação. Área de concentração: Computação Visual

Aprovada em DEZEMBRO de 2018.

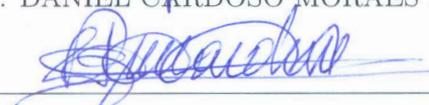
BANCA EXAMINADORA



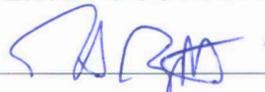
Profª. DANIELA GORSKI TREVISAN - Orientador, UFF



Prof. DANIEL CARDOSO MORAES DE OLIVEIRA, UFF



Profª. FLAVIA CRISTINA BERNARDINI, UFF



Prof. ROGÉRIO ARENA PANIZZUTTI, ICB/UFRJ

Niterói

2018

Dedico o meu trabalho a Deus, à minha esposa, aos meus pais e em memória aos meus avós maternos.

Agradecimentos

Em primeiro lugar, gostaria de agradecer a Deus por todas as graças recebidas ao longo da minha vida e à Maria Santíssima, que estão sempre presentes em minha vida e atendendo minhas preces. Agradeço também:

A minha esposa, Carolina Sacramento, por todo amor, apoio, compreensão, parceria e carinho em todos os momentos, principalmente nos mais difíceis. Eu te amo!

Aos meus queridos pais, que sempre me apoiaram e incentivaram em tudo que faço. Tenho muito orgulho de ser seu filho.

Aos meus avós maternos, que já não se encontram entre nós, mas foram pessoas guerreiras, exemplos de pais, aos quais tenho um grande carinho e respeito.

Ao meu querido irmão, pelo companheirismo e amizade; meus tios e tias (de sangue ou de coração), que me incentivam e ajudam muito, com seu carinho e apoio; meu sogro e cunhados, que me tratam com muito carinho e respeito; a avó materna da minha esposa que foi uma avó do coração e que me ajudou muito, mas que não se encontra mais entre nós; a avó paterna e tia da minha esposa que me ajudaram muito durante esse período. Muito obrigado, família!

Agradeço com carinho a professora Daniela Trevisan, minha orientadora, e ao professor Daniel de Oliveira, mesmo não sendo o meu coorientador oficial, por todo o apoio, ajuda, ensinamentos, paciência e sabedoria até o fim. E também por ambos terem acreditado no meu potencial e me aceitado como aluno. Aprendi muito com vocês e quero continuar aprendendo!

A toda equipe da PUC, principalmente o Rogério, Yasmin, Linda e Érica que me apoiaram e me ajudaram quando eu precisei de informações e esclarecimento de dúvidas.

Aos professores da banca, muito obrigado por aceitarem o convite. É uma honra ser avaliado por vocês!

À direção da Instituto Federal do Rio de Janeiro por todo incentivo, em especial ao Sérgio Moraes, ao Diretor de Ensino, à época, Isaque, pelo coordenador do curso

técnico Bruno Costa, pelo atual Diretor de Ensino João pelo apoio, paciência, respeito e consideração em, algumas ocasiões me liberarem para as reuniões do mestrado e aos amigos Daysi Luidi e Anne, que me ajudaram com palavras amigas e de carinho.

Aos professores do PPGI Sean Siqueira e Simone Bacellar Leal Ferreira, com os quais tive apoio e oportunidade de aprender, no tempo em que estive na UNIRIO. Agradeço muito a vocês!

Aos amigos queridos da UFF: José Ramón, Isela Mendoza que me ajudaram em algumas ocasiões. Principalmente, aos amigos Leonardo Vasconcelos e Carlos Eduardo, técnico administrativo da UFF que me ajudaram e me apoiaram muito com sua amizade, conselhos e profissionalismo. Muito obrigado!

À amiga que me incentiva desde o começo dessa jornada: Calquita e ao amigo Frederico Orofino por suas dicas sobre mapeamento de processos.

Agradeço também à minha professora e orientadora da graduação Maria Alice Silveira de Brito, que me incentivou muito a continuar estudando.

Por último, agradeço à Belinha, minha cachorrinha, por sua companhia ter tornado a reta final mais alegre.

Resumo

A redução das habilidades cognitivas é uma ação natural do processo de envelhecimento. O treinamento cognitivo computadorizado é um dos recursos utilizados por pesquisadores da área da saúde para melhorar as capacidades cognitivas de idosos. Aplicações na área da ciência da vida geralmente envolvem um volume considerável de dados de vários tipos e uma diversidade de ferramentas para gerenciá-los, analisá-los e interpretá-los. Existem muitos problemas desafiadores no processamento de tais dados, requerendo apoio efetivo de teorias, métodos e tecnologias inovadoras. Neste contexto, esta dissertação busca gerar soluções e contribuições em 3 áreas de conhecimento: captura e organização do conhecimento, modelagem do conhecimento e por fim extração do conhecimento. O objetivo norteador da pesquisa é investigar se o uso combinado de técnicas de visualização de dados, análise e mineração de dados pode ser um recurso útil que auxilie os pesquisadores da área de saúde a extrair padrões que melhor orientem e personalizem o treinamento cognitivo computadorizado com idosos. Esta pesquisa foi desenvolvida com base em estudo de caso do projeto de pesquisa Treinamento Cerebral Computadorizado para Idosos (Academia do Cérebro) junto ao Serviço de Psicologia Aplicada (SPA) da PUC-Rio. Após criar os modelos conceitual e físico do treinamento cognitivo computadorizado, utilizamos técnicas de mineração de dados (algoritmo k-means) para extração dos padrões. Os resultados experimentais obtidos demonstraram a eficácia do treinamento com idosos, principalmente para os jogos que exploram habilidades de memória, atenção e velocidade de processamento, e apontaram caminhos a serem explorados em novos treinamentos.

Palavras-chave: jogos cognitivos computadorizados, idosos, mineração de dados, proveniência, modelagem conceitual.

Abstract

The reduction of cognitive abilities is a natural action of the aging process. Computerized cognitive training is one of the resources used by healthcare researchers to improve the cognitive abilities of the elderly. Applications in the field of life science generally involve a considerable amount of data from different types and a variety of tools to manage, analyze and interpret them. There are many challenging problems in health data processing that require effective support of innovative theories, methods, and technologies. In this context, this dissertation seeks to generate solutions and contributions in three areas of knowledge: capture and organization, knowledge modeling and finally extraction of knowledge. As a main objective, this research provides an investigation of how the combined use of statistical analysis, data mining and visualization techniques can help healthcare researchers to extract patterns that can better guide the cognitive training of the elderly. This research was developed based on a case study of the Brain Academy Research Project, together with the Applied Psychology Service (SPA) of PUC-Rio. After creating the conceptual and physical models of computerized cognitive training, we applied data mining techniques (k-means algorithm) to extract the patterns. The experimental results demonstrated the efficacy of training with older adults mainly in games that explore memory skills, attention and processing speed and pointed out ways to be explored in new training.

Keywords: computerized cognitive games, elderly people, data mining, provenance, conceptual modeling.

Lista de Figuras

| | | |
|-----|---|----|
| 2.1 | O Diagrama de Classe PROV-DM (W3C, 2013) | 24 |
| 3.1 | Ambiente de realização do projeto Treinamento Cerebral Computadorizado para Idosos (Academia do Cérebro). Fonte: Equipe do projeto | 37 |
| 3.2 | Grupos de jogos (BRAINHQ, 2018) | 38 |
| 3.3 | Linha do tempo de um treinamento cognitivo computadorizado com uso de jogos. | 42 |
| 4.1 | Trecho do modelo CogTraining-DM | 50 |
| 4.2 | Exemplo de consulta SQL ao modelo físico criado | 52 |
| 4.3 | Trecho dos dados do grupo habilidade memória | 58 |
| 4.4 | Exemplo de gráfico radar de um dos participantes do treinamento. | 62 |
| 4.5 | Mapa do processo da pesquisa em notação BPMN | 63 |
| 4.6 | Mapa da atividade "Adquirir o conhecimento" em notação BPMN. | 64 |
| 4.7 | Mapa da atividade "Modelar o conhecimento" em notação BPMN | 65 |
| 4.8 | Mapa da atividade "Extrair o conhecimento" em notação BPMN. | 66 |
| 5.1 | Clusters gerados para os exames do grupo memória, considerando $K=3$ | 68 |
| 5.2 | Gráficos radar de cada participantes do cluster C1 e $K=3$ (com 35 amostras). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja) | 69 |
| 5.3 | Gráficos radar de cada participantes do cluster C2 e $K=3$ (com 35 amostras). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja) | 70 |
| 5.4 | Gráficos radar de cada participantes do cluster C3 e $K=3$ (com 35 amostras). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja) | 71 |

| | | |
|------|--|----|
| 5.5 | Clusters gerados para os exames dos grupos memória, funcionalidade, atenção e velocidade de processamento, considerando $K=3$ | 75 |
| 5.6 | Gráficos radar de cada participante do cluster C1 e $K=3$ (com 35 amostras). Pontuações nos exames dos grupos memória, funcionalidade, atenção e velocidade de processamento. Avaliações AV1 (em azul) e AV2 (em laranja) | 76 |
| 5.7 | Gráficos radar de cada participante do cluster C2 e $K=3$ (com 35 amostras). Pontuações nos exames dos grupos memória, funcionalidade, atenção e velocidade de processamento. Avaliações AV1 (em azul) e AV2 (em laranja) | 77 |
| 5.8 | Gráficos radar de cada participante do cluster C3 e $K=3$ (com 35 amostras). Pontuações nos exames dos grupos memória, funcionalidade, atenção e velocidade de processamento. Avaliações AV1 (em azul) e AV2 (em laranja) | 78 |
| 5.9 | Clusters gerados para os exames do grupo memória, considerando $K=4$. . . | 84 |
| 5.10 | Gráficos radar de cada participantes do cluster C1 e $K=4$ (com 51 amostras). Pontuações nos exames do grupo Memória. Avaliações AV1 (em azul) e AV2 (em laranja) | 85 |
| 5.11 | Gráficos radar de cada participantes do cluster C2 e $K=4$ (com 51 amostras). Pontuações nos exames do grupo Memória. Avaliações AV1 (em azul) e AV2 (em laranja) | 86 |
| 5.12 | Gráficos radar de cada participantes do cluster C3 e $K=4$ (com 51 amostras). Pontuações nos exames do grupo Memória. Avaliações AV1 (em azul) e AV2 (em laranja) | 87 |
| 5.13 | Gráficos radar de cada participantes do cluster C4 e $K=4$ (com 51 amostras). Pontuações nos exames do grupo Memória. Avaliações AV1 (em azul) e AV2 (em laranja) | 87 |
| 5.14 | Clusters gerados para os exames dos grupos memória, funcionalidade, atenção e velocidade de processamento, considerando $K=4$ | 91 |
| 5.15 | Gráficos radar de cada participantes do cluster C1 e $K=4$ (com 51 amostras). Pontuações nos exames dos grupos memória, funcionalidade, atenção e velocidade de processamento. Avaliações AV1 (em azul) e AV2 (em laranja) | 92 |
| 5.16 | Gráficos radar de cada participantes do cluster C2 e $K=4$ (com 51 amostras). Pontuações nos exames dos grupos memória, funcionalidade, atenção e velocidade de processamento. Avaliações AV1 (em azul) e AV2 (em laranja) | 93 |

- 5.17 Gráficos radar de cada participantes do cluster C3 e K=4 (com 51 amostras). Pontuações nos exames dos grupos memória, funcionalidade, atenção e velocidade de processamento. Avaliações AV1 (em azul) e AV2 (em laranja) 94
- 5.18 Gráficos radar de cada participantes do cluster C4 e K=4 (com 51 amostras). Pontuações nos exames dos grupos memória, funcionalidade, atenção e velocidade de processamento. Avaliações AV1 (em azul) e AV2 (em laranja) 94
- 5.19 Gráficos radar dos participantes dos clusters C1 e C2 que possuem resultados divergentes nos exames TIADL_FIN, TIADL_COMP e TIADL_COMIDA100
- A.1 Clusters gerados para os exames do grupo memória, considerando K=5 . . 113
- A.2 Gráficos radar de cada participantes do cluster C1 (K=5). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja) . 114
- A.3 Gráficos radar de cada participantes do cluster C2 (K=5). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja) . 115
- A.4 Gráficos radar de cada participantes do cluster C3 (K=5). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja) . 116
- A.5 Gráficos radar de cada participantes do cluster C4 (K=5). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja) . 117
- A.6 Gráficos radar de cada participantes do cluster C5 (K=5). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja) . 118
- B.1 Clusters gerados para os exames do grupo memória, considerando K=7 . . 119
- B.2 Gráficos radar de cada participantes do cluster C1 (K=7). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja) . 120
- B.3 Gráficos radar de cada participantes do cluster C2 (K=7). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja) . 121
- B.4 Gráficos radar de cada participantes do cluster C3 (K=7). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja) . 121
- B.5 Gráficos radar de cada participantes do cluster C4 (K=7). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja) . 122
- B.6 Gráficos radar de cada participantes do cluster C5 (K=7). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja) . 123

-
- B.7 Gráficos radar de cada participantes do cluster C6 (K=7). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja) . 124
- B.8 Gráficos radar de cada participantes do cluster C7 (K=7). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja) . 124

Lista de Tabelas

| | | |
|-----|---|----|
| 2.1 | Conceitos dos elementos do PROV-DM (Fonte: (W3C, 2013)) associados ao treinamento cognitivo computadorizado (TCC) | 25 |
| 3.1 | Nome, descrição e grupo de cada jogo (BRAINHQ, 2018) | 39 |
| 3.2 | Nome, descrição e grupo de cada jogo (BRAINHQ, 2018) | 40 |
| 3.3 | Nome, descrição e grupo de cada jogo (BRAINHQ, 2018) | 41 |
| 4.1 | Exames e unidades de medida relacionada | 54 |
| 4.2 | Grupos de habilidades e exames associados | 55 |
| 5.1 | Padrão encontrado - Cluster C1, K=3 35 amostras. Exames do grupo Memória. Total: 14 participantes | 72 |
| 5.2 | Padrão encontrado - Cluster C2, K=3 35 amostras. Exames do grupo Memória. Total: 12 participantes | 72 |
| 5.3 | Padrão encontrado - Cluster C3, K=3 35 amostras. Exames do grupo Memória. Total: 9 participantes | 73 |
| 5.4 | Padrão encontrado - Cluster C1, K=3 35 amostras. Exames do grupos Memória, Funcionalidade, Atenção e Velocidade de Processamento. Total: 16 participantes | 80 |
| 5.5 | Padrão encontrado - Cluster C2, K=3 35 amostras. Exames do Grupos Memória, Funcionalidade, Atenção e Velocidade de Processamento. Total: 6 participantes | 81 |
| 5.6 | Padrão encontrado - Cluster C3, K=3 35 amostras. Exames do Grupos Memória, Funcionalidade, Atenção e Velocidade de Processamento. Total: 13 participantes | 82 |
| 5.7 | Padrão encontrado - Cluster C1, K=4 51 amostras. Exames do grupo Memória. Total: 14 participantes | 88 |

| | | |
|------|---|-----|
| 5.8 | Padrão encontrado - Cluster C2, K=4 51 amostras. Exames do Grupo Memória. Total: 21 participantes | 89 |
| 5.9 | Padrão encontrado - Cluster C3, K=4 51 amostras. Exames do Grupo Memória. Total: 9 participantes | 89 |
| 5.10 | Padrão encontrado - Cluster C4, K=4 51 amostras. Exames do Grupo Memória. Total: 7 participantes | 90 |
| 5.11 | Padrão encontrado - Cluster C1, K=4 51 amostras. Exames do grupos Memória, Funcionalidade, Atenção e Velocidade de Processamento. Total: 19 participantes. | 95 |
| 5.12 | Padrão encontrado - Cluster C2, K=4 51 amostras. Exames do grupos Memória, Funcionalidade, Atenção e Velocidade de Processamento. Total: 16 participantes. | 96 |
| 5.13 | Padrão encontrado - Cluster C3, K=4 51 amostras. Exames do Grupos Memória, Funcionalidade, Atenção e Velocidade de Processamento. Total: 12 participantes | 97 |
| 5.14 | Padrão encontrado - Cluster C4, K=4 51 amostras. Exames do Grupos Memória, Funcionalidade, Atenção e Velocidade de Processamento. Total: 4 participantes | 98 |
| 5.15 | Dados demográficos dos participantes dos clusters C1 e C2 que apresentaram status distintos entre os exames | 99 |
| A.1 | Padrão encontrado para o cluster C1 e K=5. Exames do grupo Memória. Total: 08 participantes | 114 |
| A.2 | Padrão encontrado para o cluster C2 e K=5. Exames do grupo Memória. Total: 4 participantes | 115 |
| A.3 | Padrão encontrado para o cluster C3 e K=5. Exames do grupo Memória. Total: 10 participantes | 115 |
| A.4 | Padrão encontrado para o cluster C4 e K=5. Exames do grupo Memória. Total: 6 participantes | 116 |
| A.5 | Padrão encontrado para o cluster C5 e K=5. Exames do grupo Memória. Total: 7 participantes | 117 |

| | | |
|-----|---|-----|
| B.1 | Padrão encontrado para o cluster C1 e K=7. Exames do grupo Memória. Total: 3 participantes | 120 |
| B.2 | Padrão encontrado para o cluster C2 e K=7. Exames do grupo Memória. Total: 5 participantes | 120 |
| B.3 | Padrão encontrado para o cluster C3 e K=7. Exames do grupo Memória. Total: 5 participantes | 121 |
| B.4 | Padrão encontrado para o cluster C4 e K=7. Exames do grupo Memória. Total: 6 participantes | 122 |
| B.5 | Padrão encontrado para o cluster C5 e K=7. Exames do grupo Memória. Total: 4 participantes | 122 |
| B.6 | Padrão encontrado para o cluster C6 e K=7. Exames do grupo Memória. Total: 9 participantes | 123 |
| B.7 | Padrão encontrado para o cluster C7 e K=7. Exames do grupo Memória. Total: 3 participantes | 123 |

Sumário

| | | |
|----------|--|-----------|
| 1 | Introdução | 17 |
| 1.1 | Relevância da pesquisa | 18 |
| 1.2 | Objetivo e questões de pesquisa | 20 |
| 1.3 | Estrutura da dissertação | 20 |
| 2 | Revisão da Literatura | 22 |
| 2.1 | Proveniência de dados em jogos | 22 |
| 2.1.1 | Padrão PROV | 23 |
| 2.1.2 | Análise de dados de jogos com base na proveniência | 26 |
| 2.2 | Abordagens para extração do conhecimento | 27 |
| 2.2.1 | Mineração de dados | 27 |
| 2.2.2 | Mineração de dados para extração de conhecimento na área da saúde | 28 |
| 2.2.3 | Mineração de dados para extração de conhecimento em jogos | 31 |
| 2.3 | Abordagens para avaliação do treinamento cognitivo computadorizado . . . | 33 |
| 3 | Estudo de Caso | 36 |
| 3.1 | Projeto e equipe | 36 |
| 3.2 | Treinamento cognitivo computadorizado | 37 |
| 3.2.1 | Triagem | 43 |
| 3.2.2 | Intervenções | 44 |
| 3.2.3 | Avaliações | 45 |
| 4 | Metodologia de Pesquisa | 47 |

| | | |
|----------|--|------------|
| 4.1 | Captura e aquisição do conhecimento | 48 |
| 4.2 | Modelagem do conhecimento | 48 |
| 4.3 | Extração de conhecimento | 52 |
| 4.3.1 | Medida de superioridade estocástica/probabilística | 52 |
| 4.3.2 | Mineração de dados para descoberta de padrões | 54 |
| 4.4 | Modelo do processo da pesquisa | 62 |
| 5 | Resultados Experimentais | 67 |
| 5.1 | Mineração de dados com 35 amostras do grupo intervenção | 67 |
| 5.2 | Mineração de dados com 51 amostras dos grupos intervenção e controle . . | 83 |
| 5.3 | Discussão dos resultados com a literatura existente | 102 |
| 6 | Conclusão e Trabalhos Futuros | 105 |
| | Referências | 107 |
| | Apêndice A - Clusters e padrões encontrados para K=5 (exames grupo Memória) | 113 |
| | Apêndice B - Clusters e padrões encontrados para K=7 (exames grupo Memória) | 119 |

Capítulo 1

Introdução

De acordo com a Organização Mundial de Saúde - OMS, pela primeira vez na história a maioria das pessoas pode esperar viver até os sessenta anos, idade em que uma pessoa é considerada idosa no Brasil pelo Estatuto do Idoso (Lei 10.741/2003) (Brasil. Presidência da República. Casa Civil, 2003). Em países em desenvolvimento, como o Brasil, esta realidade é o resultado de menores taxas de mortalidade em idades mais jovens e da redução de óbitos em consequência de doenças infecciosas (WHO. World Health Organization, 2015).

A projeção populacional publicada em 2017 pelo Departamento de Assuntos Econômicos e Sociais da Organização das Nações Unidas (ONU) (United Nations. Department of Economic and Social Affairs. Population Division, 2017) indicou que a população com mais de 60 anos da América Latina e Caribe, que na ocasião foi estimada em 12% do total, passará a ser de 25% até 2050. O Instituto Brasileiro de Geografia e Estatística (IBGE) apresentou resultados análogos ao da ONU em sua projeção populacional: existem cerca de 27 milhões de idosos no Brasil em 2018 (13,1% da população), com perspectiva de progredir para 66,2 milhões 2050, representando cerca de 28,4% do total da população (IBGE. Instituto Brasileiro de Geografia e Estatística, 2018).

Embora o envelhecimento populacional esteja relacionado à melhorias nas condições sanitárias e evolução da medicina, ele é considerado o grande desafio da saúde pública da sociedade contemporânea (LIMA-COSTA; VERAS, 2003). À medida que as pessoas envelhecem, suas necessidades de saúde tendem a se tornar mais complexas, inclusive com redução de habilidades cognitivas (WILLIAMS; KEMPER, 2010).

Memória e velocidade de reação em eventos são as habilidades cognitivas mais impactadas. Idosos que tiveram habilidades cognitivas severamente afetadas tendem a depender

mais de terceiros para suas atividades diárias como locomoção, necessidades básicas etc. Manter ou melhorar as habilidades cognitivas dos idosos é uma questão importante, ainda que aberta. Pode melhorar sua qualidade de vida, além de ser um problema de saúde pública, uma vez que cuidados especiais podem se tornar consideravelmente custosos para o governo.

Segundo Maier et al. (2015), existem métodos e técnicas capazes de melhorar as habilidades cognitivas dos idosos ou, pelo menos, retardar a perda de cognição. Alguns deles são farmacológicos (KLINGBERG, 2010) e outros baseadas em estímulos (BASAK et al., 2008). Ainda que ambas as formas apresentem resultados positivos, nesta dissertação estamos especialmente interessados em abordagens baseadas na resposta a estímulos e, mais especificamente, no treinamento cognitivo.

O treinamento cognitivo envolve o design e a execução de um conjunto de tarefas, em que cada tarefa é associada a uma habilidade cognitiva específica (por exemplo, atenção) (NETTO, 2010). É uma abordagem que tem sido tratada na área da saúde como possível auxílio na melhoria cognitiva de diversas populações, como indivíduos com esquizofrenia (PANIZZUTTI; HAMILTON; VINOGRADOV, 2013; GUERCIO et al., 2018) crianças diagnosticadas com distúrbios clínicos específicos ou dificuldades de aprendizagem, pessoas com lesão cerebral traumática e idosos (Shawn Green et al., 2019). Intervenções efetivas de treinamento cognitivo podem resultar em melhor qualidade de vida e maior independência para idosos (WHITLOCK; MCLAUGHLIN; ALLAIRE, 2012).

As tarefas de treinamento cognitivo podem ser implementadas de várias maneiras. As abordagens tradicionais de treinamento cognitivo geralmente são realizadas em formato individual ou grupo, na presença de um instrutor (KUEIDER et al., 2012). Uma das formas mais proeminentes deste tipo de treinamento tem sido o uso de jogos de computador (NETTO, 2010), por se caracterizarem como alternativa mais econômica em relação aos programas tradicionais de treinamento (melhor custo-benefício) (KUEIDER et al., 2012). No treinamento computadorizado, os idosos são apresentados a uma série de jogos e devem jogar uma sequência de sessões, em que cada sessão visa estimular uma habilidade cognitiva diferente (NARDI; TREVISAN; OLIVEIRA, 2018).

1.1 Relevância da pesquisa

Apesar da comprovada eficácia em melhorar as habilidades cognitivas em idosos (MIELKE et al., 2015), é difícil para os profissionais da área de saúde identificarem problemas ou

padrões de interação a partir das pontuações obtidas em treinamentos cognitivos computadorizados. Por exemplo, em muitos treinamentos, não existe uma maneira estruturada de armazenar e consultar os dados coletados pelos estudos, informações pessoais e históricos, anamneses, resultados de jogos, etc.

Quando se trata especificamente de jogos, padrões de interação são importantes pois permitem que o profissional de saúde avalie se um determinado jogo estimulou as mesmas áreas do cérebro em todos os participantes e contribuiu efetivamente para melhoria cognitiva dos participantes idosos. Como os pesquisadores não são especialistas em Ciência da Computação, a solução utilizada por eles para estruturar os dados de treinamento é baseada em planilhas eletrônicas. O uso dessas planilhas, embora funcional, apresenta vários problemas quando comparado ao uso de abordagens mais robustas, como Sistemas de Gerenciamento de Banco de Dados (SGBD). Além das planilhas caracterizarem-se por arquivos dispersos, o que torna difícil uma análise global dos padrões de interação, elas não são capazes de garantir integridade, controle de redundância, escalabilidade, desempenho de consulta e segurança dos dados, tal como um SGBD.

Um outro aspecto desfavorável à obtenção de padrões de interação é a forma como as informações sobre o treinamento são geradas durante todo o processo. Antes, durante e após o término do treinamento, os pesquisadores submetem os participantes a exames de avaliação e registram suas pontuações, de maneira isolada e geram um relatório com o desempenho dos participantes. No entanto, esse relatório, por si só, não é capaz de mostrar aos pesquisadores se existe um padrão que possa guiar ou até mesmo personalizar o treinamento para cada participante de forma a maximizar os ganhos, garantindo assim uma melhoria cognitiva efetiva aos idosos.

Assim, a natureza abundante, complexa e heterogênea dos dados provenientes de aplicações da área de saúde contribuiu para o surgimento de problemas desafiadores no processamento desses dados, demandando apoio efetivo de teorias, métodos e tecnologias inovadoras para aprimorar, dimensionar e otimizar o gerenciamento e o processamento dos dados (DINOV, 2016), além de permitir análises mais efetivas.

Neste contexto a presente pesquisa buscou gerar soluções e contribuições nas seguintes áreas de conhecimento:

- Captura e organização do conhecimento, a partir do acompanhamento do caso de estudo junto ao Serviço de Psicologia Aplicada (SPA) da PUC-Rio o qual contribuiu para o entendimento das diversas variáveis e suas interações no treinamento

cognitivo computadorizado.

- Modelagem do conhecimento, através da constuição de um banco de dados e de um modelo de proveniência dos dados.
- Extração do conhecimento, através do uso de técnicas de visualização, análise e mineração de dados.

1.2 Objetivo e questões de pesquisa

A presente pesquisa está inserida no cenário da captura e organização do conhecimento, modelagem do conhecimento e extração do conhecimento, e tem como objetivo principal investigar se o uso combinado de técnicas de visualização de dados, análise e mineração de dados pode ser um recurso útil que auxilie os pesquisadores da área de saúde a extrair padrões que melhor orientem e personalizem o treinamento cognitivo computadorizado com idosos.

A investigação foi norteadada pela seguinte questão de pesquisa:

Que técnicas podemos utilizar para auxiliar na identificação de padrões dos participantes idosos no treinamento de jogos cognitivos computadorizados?

A esta questão geral, estão relacionadas as seguintes questões específicas:

- Q1. Como o desempenho (*scores* e tempos dos exames) de cada participante evolui ao longo do treinamento?
- Q2. Quais são os padrões observados, que demonstram a melhora de habilidades de memória de idosos, quando submetidos a jogos cognitivos computadorizados?
- Q3. Quais são os padrões observados que demonstram a melhora de habilidades de memória, funcionalidade, atenção e velocidade de processamento de idosos, quando submetidos a jogos cognitivos computadorizados?

1.3 Estrutura da dissertação

Esta dissertação está organizada em seis capítulos. Após este capítulo introdutório, apresentamos no Capítulo 2 conceitos importantes que estão relacionados à pesquisa realizada,

como proveniência e mineração de dados, além de trabalhos relacionados sobre as temáticas de proveniência em jogos e mineração de dados aplicada à saúde e à jogos. No Capítulo 3, descrevemos o estudo de caso no qual esta pesquisa está inserida. Já no Capítulo 4, apresentamos a metodologia de pesquisa utilizada, que contempla a abordagem proposta para captura e organização dos dados em um modelo conceitual e de proveniência, técnicas de análise e mineração de dados aplicados para a identificação de padrões sobre esses dados. No Capítulo 5 discutiremos os resultados obtidos, concluindo esta dissertação, com identificação de trabalhos futuros, no Capítulo 6.

Capítulo 2

Revisão da Literatura

Neste capítulo, apresentaremos abordagens e estudos realizados que estão, de alguma forma, relacionados à proposta desta dissertação. O capítulo foi dividido em três seções: 2.1 - Proveniência de dados em jogo, onde apresentamos o padrão PROV (subseção 2.1.1) e alguns trabalhos que utilizam proveniência para análise de dados em jogos (subseção 2.1.2); 2.2 - Abordagens para extração do conhecimento, onde apresentamos a definição de mineração de dados (subseção 2.2.1), bem como trabalhos que utilizaram estratégias de mineração de dados para extração de conhecimento na área da saúde (subseção 2.2.2) e no contexto de jogos (subseção 2.2.3); e 2.3 - Abordagens utilizadas para avaliação do treinamento cognitivo computadorizado, em que apresentamos algumas soluções utilizadas para avaliar o desempenho cognitivo entre grupos de participantes idosos, na interação com jogos cognitivos computadorizados.

2.1 Proveniência de dados em jogos

O termo "Proveniência" é utilizado para fazer referência à origem do dado (BUNEMAN; KHANNA; WANG-CHIEW, 2001) e tem por finalidade registrar informações que representam o histórico de um dado e de como esse dado foi produzido ou derivado (BUNEMAN; KHANNA; TAN, 2000; BUNEMAN; KHANNA; WANG-CHIEW, 2001; ÁLVAREZ et al., 2006; FREIRE et al., 2008). Assim, Buneman et al. (BUNEMAN; KHANNA; WANG-CHIEW, 2001) foram os primeiros autores a definir proveniência em procedimentos científicos, considerando o termo como a descrição da origem de um dado e o processo pelo qual ele é armazenado em um banco de dados.

Em geral, a proveniência pode ser caracterizada de duas maneiras: prospectiva e retrospectiva (LIM et al., 2010). A proveniência prospectiva está interessada em capturar

e armazenar dados sobre a estrutura do processo que levou à geração de um determinado produto (o procedimento científico). Com isso, podemos dizer que, no contexto desta dissertação, a proveniência prospectiva diz respeito ao processo de treinamento cognitivo computadorizado realizado pela equipe da PUC-Rio que permitiu o mapeamento das entidades e informações relevantes envolvidas no treino, como dados dos participantes, os jogos e as avaliações realizadas.

A proveniência retrospectiva concentra-se em capturar os dados e seus descritores produzidos a partir da execução de certas atividades. Os dados de proveniência retrospectiva incluem por exemplo os tempos de início e término de uma sessão de jogo, as pontuações obtidas pelo participante e os erros ocorridos.

2.1.1 Padrão PROV

Para armazenar os dados de proveniência retrospectiva e prospectiva, os modelos de dados devem seguir o padrão W3C PROV (W3C, 2013). PROV propõe uma representação genérica e abstrata de proveniência. A principal ideia por trás do PROV é representar os conceitos mais importantes de proveniência que podem ser especializados para diferentes domínios. Proveniência são informações sobre entidades, atividades e pessoas envolvidas na produção de um dado, que podem ser usadas para formar avaliações sobre sua qualidade, segurança ou confiabilidade. O PROV é um modelo de dados conceitual que forma uma base para a família de especificações de proveniência do W3C (PROV) (que inclui modelos de dados, ontologias, scripts etc). O modelo de dados PROV é composto, em uma anotação UML (*Unified Model Language*), por 3 classes: agente, entidade e atividade. Além disso, é composto por 7 relacionamentos entre essas 3 classes: "WasGeneratedBy", "Used", "WasInformedBy", "WasDerivedFrom", "WasAttributedTo", "WasAssociatedWith" e "ActedOnBehalfOf", conforme apresentado na Figura 2.1.

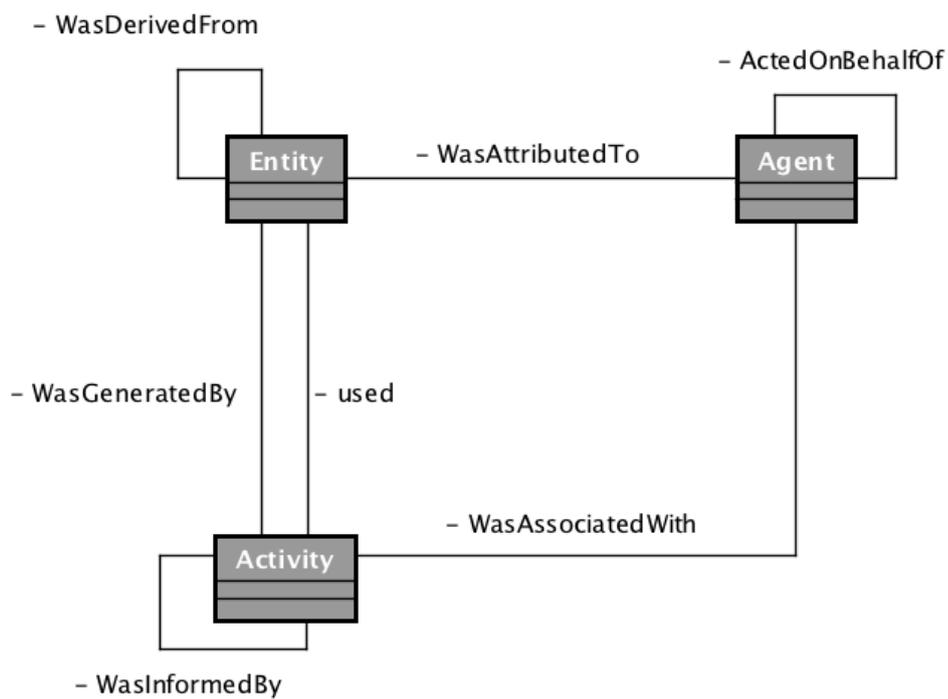


Figura 2.1: O Diagrama de Classe PROV-DM (W3C, 2013)

Para apoiar o entendimento dos elementos (classes e relacionamentos) apresentamos na tabela 2.1 os conceitos do PROV-DM associados aos elementos presentes no treinamento cognitivo computadorizado, tratados no contexto desta dissertação.

Tabela 2.1: Conceitos dos elementos do PROV-DM (Fonte: (W3C, 2013)) associados ao treinamento cognitivo computadorizado (TCC)

| Elementos | Tipo | Conceitos PROV-DM | Relação com TCC |
|---|----------------|---|---|
| Entity (Entidade) | Classe | Um tipo físico, digital, conceitual ou outro tipo de objeto com alguns aspectos fixos; podendo ser reais ou imaginárias | Um jogo |
| Activity (Atividade) | Classe | Algo que ocorre ao longo de um período de tempo e age sobre uma ou muitas entidades; pode incluir consumir, processar, transformar, modificar, realocar, usar ou gerar entidades | Uma sessão de jogo |
| Agent (Agente) | Classe | Algo que tem alguma forma de responsabilidade por uma atividade que está ocorrendo, pela existência de uma entidade ou pela atividade de outro agente | Um indivíduo específico que interage com o treinamento |
| Used (Usado por) | Relacionamento | Uma Entity é usada por uma Activity . Esse uso ocorre ao longo da sua execução, ou seja, do início ao fim do processo | Uma "sessão do jogo" se utiliza de um "jogo" |
| WasGeneratedBy (Gerado por) | Relacionamento | Uma nova Entity foi gerada por uma Activity | Quando uma "sessão de jogo" é estabelecida, "jogos", são definidos ou gerados para que ocorra a interação entre o participante e a sessão do jogo no momento do treinamento |
| WasAssociatedWith (Associado com) | Relacionamento | Uma Activity está relacionada ou ligada a um Agent | Uma vez estabelecida a "sessão do jogo", cria-se um vínculo com o participante que irá interagir com essa "sessão" |
| WasDerivedFrom (Derivado de) | Relacionamento | Uma Entity original foi utilizada direta ou indiretamente para transformar, construir ou atualizar outra Entity derivada | um "jogo" pode ter sido derivado, direta ou indiretamente, de outro "jogo". |
| WasInformedBy (Informado por) | Relacionamento | uma Entity criada ou gerada por uma Activity pode ser utilizada por outra Activity | um "jogo", definido para uma "sessão de jogo", que pode ser utilizado por outra "sessão de jogo" |
| WasAttributedTo (Atribuído a) | Relacionamento | Confere a concessão de uma Entity a um Agent , ou seja, um Agent possui algum tipo de responsabilidade sobre uma Entity | Aguns "jogos" são concedidos ou atribuídos a um "participante" no treinamento |
| ActedOnBehalfOf (Atua em nome de) | Relacionamento | Confere a um Agent atribuir responsabilidade para outro Agent , ou seja, ação de um Agent em nome de outro Agent para realizar alguma atividade como procurador | Não se aplica tal concessão de responsabilidade no contexto desta dissertação |

Uma das principais vantagens do uso de padrões e recomendações como o PROV, aplicado ao contexto de interesse da nossa dissertação, é garantir a interoperabilidade dos descritores de proveniência de ambientes heterogêneos, independentemente da tecnologia e abordagem utilizada.

2.1.2 Análise de dados de jogos com base na proveniência

O trabalho intitulado "Spielzyklus: Identificando Padrões de Ciclos em Dados de Proveniência Extraídos de Forma não Intrusiva" (JACOB, 2015) tem por objetivo disponibilizar aos desenvolvedores de jogos uma ferramenta para identificar ciclos em sessões de jogo, permitindo assim um estudo do comportamento dos jogadores durante várias sessões. Portanto, essa ferramenta buscou auxiliar o desenvolvedor do jogo a identificar sequências de passos que se repetem utilizando técnicas de mineração de padrões, conhecendo assim que partes do jogo devem ser aprimoradas, com intuito de melhorar a sua qualidade. Ao analisar os dados do jogo, o desenvolvedor pode obter informações úteis sobre ciclos, características e a mecânica de jogo para novas produções ou futuras atualizações do mesmo.

Em Jacob (2015), a análise e o processamento de imagens para a captura das sessões/sequências durante a execução de uma sessão do jogo foram realizados a partir de método não intrusivo. O método proposto visa detectar os agentes e entidades envolvidos na cena, utilizando histogramas (indica o percentual de "pixels" na imagem analisada que apresentam uma determinada tonalidade de cor). Desta forma, com as imagens-modelo fornecidas e as imagens da sessão do jogo podemos identificar os elementos comparando os histogramas de cada modelo com o histograma de cada parte da imagem. Após a identificação dos modelos é verificado se ocorreu uma ação (por exemplo, o personagem toca um inimigo), armazenando todas as ações e informações associadas no repositório de proveniência. Este repositório de proveniência é utilizado pelo "Prov Viewer", uma ferramenta de visualização baseada em grafo para exploração interativa de dados de proveniência ¹. Este repositório também é utilizado para extrair informações para a etapa de mineração de dados.

A mineração dos dados nos dados de proveniência possibilita a aquisição de informações em grandes quantidades de dados. Estas informações são difíceis de serem observadas visualmente nos grafos. Analisando informações mineradas e o grafo de proveniência, o desenvolvedor de jogos poderá identificar um ciclo em uma sessão de jogo, entender por

¹<https://github.com/gems-uff/prov-viewer>

que está ocorrendo e verificar o impacto na jogabilidade. Por meio destes recursos o desenvolvedor de jogos poderá planejar jogos que serão desenvolvidos ou corrigir erros em uma versão do jogo.

2.2 Abordagens para extração do conhecimento

Grandes volumes de dados e informações são gerados e armazenados em bases de dados, tanto para fins de negócios ou acadêmicos/científicos, nas mais diversas áreas do conhecimento, incluindo o campo médico. Essa realidade traz uma crescente demanda de acesso a esses dados para tomada de decisão. No entanto, a extração de conhecimento e informações estratégicas nesse cenário nem sempre é evidente, pois o grande volume de dados dificulta consultas, manipulações e análises dos mesmos. Para tal, torna-se necessário utilizar técnicas de descoberta de conhecimento em bases de dados (KDD, do inglês *Knowledge Discovery in Databases*) e mineração de dados (*data mining*).

Com o objetivo de melhor esclarecer a diferença entre os termos KDD e *data mining*, Goebel e Gruenwald (1999) definem KDD como o processo de transformar um grande volume de dados de baixo nível, que não são facilmente compreensíveis pelo analista, em dados de fácil compreensão ou conhecimento de alto nível, relacionando os dados e identificando padrões relevantes, novos e válidos. Além disso, definem a mineração de dados como extração de conhecimento ou padrão em um grande volume de dados armazenados na base de dados.

2.2.1 Mineração de dados

Mineração de dados consiste em explorar e analisar grandes volumes de dados no intuito de descobrir regras e padrões significativos. Com isso, a mineração de dados tem dois objetivos principais: descrição e predição. Na descrição, o foco é descobrir relacionamentos entre os dados da base, enquanto que na predição, o foco é propiciar previsões de tendências futuras com base em dados do passado (análise histórica dos dados armazenados na base) (BERRY; LINOFF, 2004).

A mineração de dados está relacionada à construção de modelos, algoritmos ou um conjunto de regras que ligam entradas - que são geralmente os campos ou atributos de uma base de dados - a um resultado ou saída específica. Com base nisso, a mineração de dados se destaca em dois tipos: Direta e Indireta. Na direta, a partir de informações de entrada, tenta-se categorizar ou explicar alguma saída, resposta ou resultado específico.

Na indireta, busca-se encontrar similariedade ou padrões entre os grupos de dados, sem focar em uma determinada saída ou um conjunto de classes específicas (BERRY; LINOFF, 2004).

2.2.2 Mineração de dados para extração de conhecimento na área da saúde

Jothi, Rashid e Husain (2015) realizaram uma revisão de literatura no período de 2005 a 2015, buscando artigos completos contendo a frase: "aplicação de técnicas de mineração de dados na área da saúde" nos bancos de dados online ScienceDirect, Springerlink e IEEE Xplore. Após filtragem de tópicos sob os 3.840 artigos encontrados nas bases, os autores consolidaram 50 artigos que tratam aspectos relacionados a disciplinas, modelos, tarefas e métodos de mineração de dados aplicados à saúde. Quanto às disciplinas, os autores identificaram que Aprendizado de Máquina é a que possui maior incidência nos artigos selecionados (40 dos 50), seguida por Inteligência Artificial (5 artigos), Estatística (3) e Probabilidade (2). No que diz respeito a modelos, os autores reconheceram que existem dois tipos: preditivos, que aplicam funções de aprendizado supervisionadas para prever valores desconhecidos ou futuros e descritivos, que aplicam funções de aprendizado não supervisionados na descoberta de padrões nos dados, para interpretação posterior de especialistas. Os modelos preditivos estiveram presentes na maior parte das pesquisas selecionadas: 47 de 50 artigos. Já em relação às tarefas de mineração geralmente utilizadas na implementação de modelos, a Classificação foi a de maior incidência, presente em 42 dos 50 artigos. Regras de Associação (5 artigos relacionados), Clusterização (2 artigos) e Detecção de anomalias (1 artigo), embora em menor número, também têm sido utilizadas no contexto da saúde. Por fim, no que diz respeito à métodos de mineração de dados, os autores identificaram as seguintes contribuições para área de saúde e, posteriormente, os algoritmos de mineração de dados associados a tais abordagens:

- **Detecção de anomalias:** *standard support vector data description, density induced support vector data description e Gaussian mixture*
- **Clusterização:** *vector quantization method*
- **Classificação:** *statistical, discriminant analysis, decision tree, Markov based, swarm intelligence, k-nearest neighbor, genetic classifiers, artificial neural network, support vector e association rule*

Embora não tenha detalhado os procedimentos metodológicos utilizados, o trabalho de Pandey (2016) apresenta uma visão geral da mineração de dados aplicada ao contexto da saúde. O autor indica as principais tarefas de mineração de dados relacionadas ao domínio médico, explicando cada uma delas: Sumarização, Associação, Classificação, Clusterização, Análise de tendências e Regressão. Além disso, apresenta categorias de aplicação da mineração de dados na área: Diagnóstico e prognóstico de doenças (um dos mais importantes usos de mineração de dados para a saúde, segundo o autor); Ranking de hospitais (estudo das características de vários hospitais, a fim de classificá-los); Identificação de melhores técnicas de tratamento (em relação a eficácia e custo); Análise da eficácia de um tratamento (comparando fatores como causas, sintomas, efeitos colaterais e custo); Melhoria da qualidade de serviços de saúde prestados; Controle de infecção em hospitais (a partir da identificação de padrões irregulares nos dados de controle de infecção); Identificação de pacientes de alto risco; Redução na fraude e abuso de seguros; Gestão de recursos hospitalares e Análise de dados de sensores e dispositivos médicos.

Pandey (2016) também abordou a importância da gestão do conhecimento (GC) nesse domínio (métodos e técnicas de GC), a fim de maximizar o desempenho organizacional e operacional nos procedimentos de coleta, gestão, uso, análise, compartilhamento e descoberta do conhecimento. E continua a discussão apresentando as técnicas de mineração de dados utilizadas no campo saúde (Redes Neurais, Árvores de Decisão, Conjuntos Fuzzy, Support Vector Machine (SVM), Redes Bayesianas, *Rough Set* e Algoritmos Genéticos), bem como as vantagens e desvantagens de cada uma delas em tal contexto. O autor apresenta também os métodos de aprendizagem de máquina para área da saúde, classificando-os como simbólicos (por exemplo, árvores de decisão) e sub-simbólicos (algoritmos genéticos e redes neurais artificiais), com base na natureza da manipulação durante processo de aprendizado de máquina. E finaliza o *overview* discutindo sobre as particularidades dos dados médicos: são mais difíceis de minerar em comparação com outros conjuntos de dados, pois costumam ser muito grandes, heterogêneos por natureza e possuem restrições legais, éticas e sociais. Ainda sobre a singularidade dos dados médicos, o autor destaca uma forte filosofia estatística na área médica e indica que testes estatísticos clássicos em medicina podem levar a resultados ambíguos, o que torna a mineração de dados complemento interessante para área, uma vez que lida com grande volumes de dados heterogêneos. Nesse contexto, é fundamental que os dados sejam estruturados e organizados para o sucesso na aplicação das técnicas de mineração de dados.

Especificamente sobre clusterização, a pesquisa Veloso et al. (2014) buscou identificar a similaridade de grupos de pacientes para entender porque pessoas liberadas da Unidade de

Tratamento Intensivo (UTI) voltavam a ser internadas com menos de 30 dias da liberação. O objetivo de utilizar clusterização foi apoiar as decisões clínicas, reduzindo o número de readmissões de pacientes à UTI. Foram utilizados dados reais, extraídos de uma base de dados que armazena o processo clínico do paciente e resultados laboratoriais no período de 2010 a 2014 (36 registros de readmissão, correspondente a 3.5% do montante de 1.043 episódios). Após etapa de entendimento do negócio e dos dados da base utilizada, os autores realizaram uma preparação dos dados, a partir da criação de atributos derivados da base principal para atender ao modelo SWIFT (*Stability and Workload Index for Transfer*) – uma escala (*score*) de avaliação de riscos. Na sequência, os autores criaram o modelo da clusterização que incluiu, além do *score* de risco, informações demográficas do paciente, resultados de exames laboratoriais, entre outros. Os autores compararam a aplicação de três algoritmos de clusterização: k-means, k-medoids, x-means sob o conjunto de dados criado com base no modelo proposto, concluindo que o k-means foi o algoritmo que apresentou melhor desempenho. Os clusters gerados com o k-means permitiram aos especialistas perceberem que aspectos como sexo e *scores* SWIFT não tiveram impacto sobre os grupos. As variáveis que influenciam o número de readmissões são as relacionadas aos exames laboratoriais (*Lactic Acid* e *Leucocytes*), tempo de permanência no hospital, idade, taxas de oxigênio e dióxido de carbono no sangue (*PaO₂/FIO₂ Ratio*, *PaCO₂*) e local de origem do paciente (enfermaria, sala de emergência).

Uma abordagem que tratou aspectos cognitivos com uso de mineração de dados foi a de Marcano-Cedeño et al. (2013). Os autores aplicaram técnicas de mineração para prever os resultados da reabilitação cognitiva em pacientes com lesão cerebral adquirida (traumatismo cranioencefálico), usando três diferentes algoritmos: Árvores de Decisão, *Multilayer Perceptron* e Redes Neurais de Regressão Geral. Os dados utilizados na mineração foram obtidos na PREVIRNEC: uma plataforma de tele reabilitação cognitiva criada em 2005 na Espanha (parceria entre *Universitat Rovira i Virgili*, *Technical University of Madrid* e o *Institut Guttmann Neurorehabilitation Hospital*), que armazena informações de 1.120 pacientes (um total de 183.047 tarefas de reabilitação executadas). Os autores avaliaram a precisão dos algoritmos de predição, utilizando medidas de desempenho como: especificidade, sensibilidade, precisão e matriz de confusão (ou contingência) e validaram os resultados obtidos com o método *k-fold cross-validation* (com $k = 10$). Este método buscou minimizar o viés associado à amostragem aleatória do treinamento, pois divide o conjunto de dados aleatoriamente em k subconjuntos mutuamente exclusivos e aproximadamente iguais. No método, o algoritmo de classificação é treinado e testado k vezes. Como resultado, os autores identificaram que o algoritmo de Árvores de Decisão

obteve melhor performance (em termos de especificidade, sensibilidade, precisão e matriz de contingência) e estabilidade (comparando o desvio padrão) em relação aos outros algoritmos. Os 90,38% de acurácia média de predição obtidos no algoritmo do tipo Árvores de Decisão indicaram ser possível estimar os resultados da reabilitação de pacientes com lesão cerebral adquirida em função do perfil dos mesmos, obtido a partir da avaliação neuropsicológica inicial e de dados do processo de reabilitação do paciente coletados na plataforma PREVIRNEC.

2.2.3 Mineração de dados para extração de conhecimento em jogos

À medida que o processo de interação ocorre, é provável que o paciente desenvolva estratégias que o façam adquirir conhecimentos e, assim, ganhar o jogo com mais facilidade. Nesse contexto, He et al. (2008) apresentam uma abordagem que consiste em identificar estratégias utilizadas por cada participante durante a sessão do jogo, a partir de análise dos log. Essa abordagem é chamada de Reconhecimento de Padrão de Estratégia do Jogador (da sigla em inglês PSPR), na qual pode melhorar significativamente a adaptabilidade do jogo de Inteligência Artificial (AI). Nesse cenário, He et al. (2008) aplicaram o algoritmo de classificação *Radial Basis Function Networks* (RBFN) no jogo do Pac-Man Test-bed desenvolvido em Java por Benny Chow. Ele seguiu o mesmo projeto e estrutura do Pac-Man original. O algoritmo de classificação RBFN foi usado para identificar, analisar e extrair padrões de interação de cada jogador, a partir de três diferentes estratégias pré-estabelecidas no jogo (Estratégia A: o Pac-Man se mantém estático, após "energização", até final do ciclo; Estratégia B: Após "energização", o Pac-Man busca eliminar os fantasmas e Estratégia C: após "energização", o Pac-Man busca comer as pastilhas e não os fantasmas). Assim, a tentativa do método proposto pelos autores é usar o classificador de treinamento (RBFN) para prever futuros padrões de estratégia de jogadores com base nos dados capturados de seu jogo. Além disso, os autores propõem uma comparação do classificador RBFN, aplicado ao jogo do Pac-Man, com outros classificadores como o "*Support Vector Machine* (SVM)", "*Naive Bayes* (NB)" e "*Bayesian Belief Networks*". Com isso, esse trabalho se mostrou relevante, pois a ideia era buscar a eficácia e eficiência do algoritmo RBFN aplicado ao jogo em comparação com os outros algoritmos.

Karlini e Rigo (2014) propõem um modelo de integração em que permita ao professor ter acesso à sessão do jogo do aluno, ou seja, aos acontecimentos ocorridos enquanto o aluno está interagindo com o jogo. Além disso, esse artigo tem o objetivo de apresentar

um modelo que integre os jogos sérios com a mineração de dados, fornecendo como base um jogo online voltado ao letramento. Nesse cenário, os dados relevantes gerados do jogo são capturados, armazenados em arquivo texto (log) e transportados para uma ferramenta de mineração de dados em que permitem aos professores realizar diversas análises. Com isso, os autores utilizam da ferramenta de mineração de dados *Toolkit Weka* que contém um conjunto de algoritmos de mineração de dados. Nesse contexto, com base na proposta pelos autores de um jogo que contém atividades de alfabetização simples (ABC Lingo), foi armazenado as interações dos alunos nesse jogo. Para isso, precisou armazenar os dados como nome do aluno, nível vocálico escolhido pelo aluno, atividade realizada, todas as respostas escolhidas ou os dados que foram digitados em cada atividade, acertos, erros, hora de início e fim do jogo, hora de início e fim de cada atividade. Desta forma foi possível identificar alguns problemas ou dificuldades dos alunos na interação com o jogo, por meio da utilização de diferentes métodos e algoritmos da ferramenta Weka aplicados ao log da execução e interação do jogo. Por exemplo, uma das abordagens utilizadas foi a análise dos dados obtidos com os logs e a sua organização em clusters ou grupos, com base em características comuns. Nesse caso, esses dados obtidos são agrupados por proximidade de características e com isso podem ajudar o professor a identificar tendências no comportamento dos alunos aos responderem as questões. Nesse cenário, foi usado o algoritmo de clusterização SimpleKmeans (Weka Project, 2018) em que realiza os agrupamentos dos conjuntos de dados com base nos aspectos comuns. Um dos padrões que os autores buscaram identificar com a técnica, por exemplo, foi a detecção de elementos incorretos nos grupos de escolhas dos alunos ao responderem as questões (dificuldade dos alunos).

Frantzidis et al. (2014) mencionam a importância do treinamento cognitivo computadorizado baseado em neuroplasticidade que pode facilitar a interação harmônica de regiões distantes do cérebro e, dessa forma, melhorar o desempenho cognitivo em pessoas idosas. O treinamento contribui para melhora da estrutura neurofisiológica do cérebro e, conseqüentemente, a prevenção da demência em participantes idosos saudáveis. Nesse cenário, os autores propõem que os participantes idosos sejam separados aleatoriamente nos grupos intervenção LLM (*Long Last Memory*) e Controle e, em seguida, desenvolvem um estudo no intuito de fornecer uma ferramenta objetiva, baseada em sincronização, para avaliar intervenções cognitivas e / ou físicas, adotando e calculando a noção de Entropia de *Wavelet* Relativa ao grau de similaridade das distribuições de energia entre cada par de eletrodos, resultando na matriz de sincronização. O modelo matemático em questão emprega uma métrica de sincronização robusta e sem parâmetros, usando técnicas de mi-

neração de dados por meio do classificador baseado na distância de Mahalanobis (Md), que é considerado simples, robusto e que oferece uma maneira quantificável de medir o impacto individual da intervenção. Com esse classificador, um valor de distância foi calculado para todos os participantes, de modo a quantificar a proximidade de seu perfil individual ao aumento médio da sincronização de grupo. Em apoio à hipótese, os resultados mostraram um aumento significativo na sincronização, para quatro pares de eletrodos, no grupo de intervenção, em comparação com o grupo controle ativo. Conclui-se que a nova introdução das características de sincronização neurofisiológica poderia ser usada como um teste válido e confiável; enquanto a análise baseada na distância de Mahalanobis (Md) poderia fornecer um meio confiável de avaliar os benefícios individuais. Cabe ressaltar que para ambos os grupos, é medido e capturado dados, por meio de eletroencefalograma (EEG), da sincronização entre áreas específicas do cérebro antes e após o treinamento cognitivo por meio de jogos computadorizados. Com isso, o objetivo é determinar se houve aumento na sincronização ou comunicação entre as áreas do cérebro estimuladas pelo treinamento para o grupo intervenção em relação ao grupo controle ativo. Com esses dados do EEG, foi possível utilizar técnica de mineração de dados, como a clusterização através do algoritmo classificador baseado na distância Mahalanobis (Md).

2.3 Abordagens para avaliação do treinamento cognitivo computadorizado

A interação dos participantes idosos em um treinamento cognitivo computadorizado através de jogos sérios que estimulam sua memória, atenção, cognição entre outras é de suma importância para prevenir os participantes de possíveis doenças degenerativas, como o Alzheimer. Nesse contexto, no artigo de Chi, Agama e Prodanoff (2017) é proposto o projeto de um conjunto de jogos sérios com base em computador e também disponibilizado de forma gratuita via navegador web, chamado “Smart Thinker”, que é usado para melhorar as habilidades cognitivas centrais, concentrando-se especificamente nas habilidades de atenção e memória. Dessa forma, os autores selecionaram 59 participantes idosos que foram separados aleatoriamente dentro de um grupo Intervenção (Tratamento) e de um grupo Controle ou Placebo (Comparação). Nesse cenário, os autores aplicaram o “Mini Mental State Examination (MMSE)” em ambos os grupos no início e no fim no período de 6 semanas e então aplicaram um teste estatístico T-Teste Student para verificar se há diferença significativa entre as médias dos grupos, e aplicaram um teste de Levene’s para verificar se há similaridade entre as variâncias dos grupos Intervenção e Controle.

Com esses testes estatísticos, eles puderam verificar qual dos grupos analisados tiveram a melhor resposta cognitiva.

O controle cognitivo é definido por um conjunto de processos neurais que nos permitem interagir em nosso ambiente complexo de forma direta. Os seres humanos desafiam regularmente esses processos de controle enquanto tentam realizar simultaneamente múltiplos objetivos (multitarefa), gerando interferência como resultado de limitações no processamento de informações-chave. Nesse contexto, Anguera et al. (2013) apresenta uma abordagem em que faz uso de um videogame tridimensional personalizado (NeuroRacer) e uma versão adaptativa do mesmo no modo de treinamento multitarefa aplicado a grupos de 20 a 79 anos e grupos de 60 a 89 anos. Nesta abordagem, Anguera et al. (2013) apontou que a plasticidade do sistema de controle cognitivo pré-frontal no envelhecimento cerebral fornece a primeira evidência, a nosso conhecimento, de como um videogame personalizado pode ser usado para avaliar habilidades cognitivas ao longo da vida, avaliar os mecanismos neurais subjacentes e servir como uma ferramenta poderosa para o aprimoramento cognitivo.

O trabalho de Whitlock, McLaughlin e Allaire (2012), por sua vez, utilizou o jogo comercial *War of Warcraft* (WoW), que possui característica *multiplayer*. Os autores escolheram o WoW por considerarem que o mesmo estimula vários aspectos cognitivos dos idosos, incluindo orientação espacial e atenção.

O experimento de Whitlock, McLaughlin e Allaire (2012) utilizou amostras de 20 participantes (grupo intervenção) e 19 participantes (grupo controle), que realizaram uma série de testes de capacidade durante sessões pré e pós-teste, com intuito de medir a cognição inicial e possíveis mudanças ao longo do período experimental. Os testes realizados pelos participantes (controle e intervenção) incluíam testes de capacidade espacial, função executiva e memória.

Apenas os participantes experimentais foram submetidos ao treinamento, sendo 2h de pré-treino, composto de palestra e demonstração (1h), seguido de treinamentos práticos com o WoW (1h) e 14h de sessões de jogos na própria casa do participante, em um período de 2 semanas.

Os pesquisadores pretendiam validar a hipótese de que o jogo WoW melhoraria a capacidade cognitiva de idosos, considerando que o mesmo estimula múltiplas habilidades cognitivas. Em particular, havia a intenção de analisar a melhoria da orientação espacial e atenção dos participantes. Além disso, os autores supunham que o nível inicial de habilidade do idoso afetaria a melhora de modo que os participantes experimentais que

apresentassem menor capacidade inicial, teriam melhores resultados em comparação com participantes de maior habilidade inicial.

Os resultados obtidos (com análise de variância ANOVA) demonstraram eficácia do jogo WoW na melhoria das habilidades cognitivas dos participantes idosos, sob as circunstâncias analisadas. Além disso, os resultados obtidos por Whitlock, McLaughlin e Allaire (2012) demonstraram não existir relacionamento entre idade e mudança cognitiva e confirmaram a hipótese de que idosos com menor nível de habilidade inicial podem se beneficiar mais do treinamento cognitivo.

Capítulo 3

Estudo de Caso

Este capítulo apresenta o estudo de caso no qual a presente pesquisa está inserida. Nele apresentamos alguns conceitos importantes para melhor entendimento da proposta. Além disso, definimos todo o processo do treinamento cognitivo computadorizado a equipe envolvida e apresentamos todos os jogos em que os participantes idosos interagem.

3.1 Projeto e equipe

Todos os procedimentos do treinamento cognitivo apresentados neste capítulo bem como questões éticas e de consentimento dos participantes seguem os regulamentos já adotados e aprovados no projeto de pesquisa Treinamento Cerebral Computadorizado para Idosos (Academia do Cérebro) coordenado pelo médico e neurocientista Prof. PhD Rogério Arena Panizzutti, do Instituto de Ciências Biomédicas (ICB) e do Instituto de Psiquiatria (IPUB) da Universidade Federal do Rio de Janeiro. O IPUB é composto por uma equipe multidisciplinar de psicólogos, profissionais de educação física e estudantes em áreas afins. A equipe do projeto realiza treinamentos cognitivos baseado em computador no Serviço de Psicologia Aplicada (SPA) do Departamento de Psicologia da Pontifícia Universidade Católica do Estado do Rio de Janeiro (PUC-Rio). Dentre os colaboradores do projeto que auxiliaram no desenvolvimento desta dissertação, destacamos Yasmin de Oliveira, Linda Scoriels, Érica Woodruff e o coordenador do projeto Prof. Dr. Rogério Panizzutti.

A Figura 3.1 ilustra o ambiente no qual o projeto em questão é realizado.



Figura 3.1: Ambiente de realização do projeto Treinamento Cerebral Computadorizado para Idosos (Academia do Cérebro). Fonte: Equipe do projeto

3.2 Treinamento cognitivo computadorizado

O treinamento cognitivo consiste em sessões semanais de jogos (geralmente jogados 3 vezes por semana), totalizando 40 horas durante 3 a 6 meses, dependendo da frequência do participante idoso. Atualmente, 21 indivíduos estão participando do treinamento com uma idade mínima de 60 anos e um máximo de 86 anos (média de 73 anos). Todos os jogos que cada indivíduo interage fazem parte da plataforma BrainHQ (MAO; CHEN; LI, 2015) e estão organizados em vários grupos: "Atenção", "Velocidade de Processamento ou Cerebral", "Memória", "Socialização", "Inteligência" e "Orientação". O grupo de jogos, bem como a ordem de execução, é definido pela equipe de pesquisadores. Esses grupos de jogos podem ser vistos, conforme a Figura 3.2. Nela observamos que há seis grupos de jogos com a seguinte descrição da esquerda para a direita: Atenção, Velocidade Cerebral, Memória, Habilidades Sociais, Inteligência e Orientação. Dessa forma, Cada um desses grupos de jogos se concentra em estimular áreas específicas do cérebro do participante idoso a fim de provocar estímulo neural ou cerebral (BRAINHQ, 2018).



Figura 3.2: Grupos de jogos (BRAINHQ, 2018)

Nas Tabelas 3.1, 3.2 e 3.3 apresentamos cada um dos jogos em que os participantes idosos interagem, juntamente com seu objetivo e grupo de exames ao qual pertence.

Tabela 3.1: Nome, descrição e grupo de cada jogo (BRAINHQ, 2018)

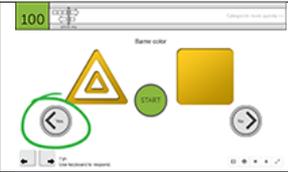
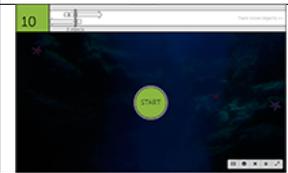
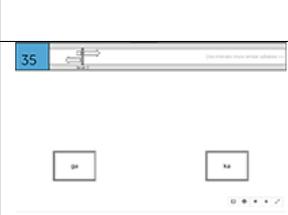
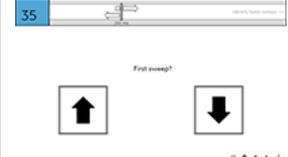
| Ilustração | Jogo | Objetivo | Grupo de Jogo |
|---|-------------------|---|---------------|
|  | Atenção Dividida | Aprimorar as capacidades de Foco e Atenção | Atenção |
|  | Decisão Dupla | Campo de visão útil e velocidade de processamento visual | Atenção |
|  | Estátua | Aprimorar o Estado de alerta | Atenção |
|  | Sinais Mistos | Aperfeiçoar a Atenção | Atenção |
|  | Olho Vivo | Aperfeiçoar as capacidades de atenção e memória | Atenção |
|  | Foco nos Detalhes | Velocidade de processamento visual e Memória de trabalho visual | Cérebro |
|  | Sintonia Fina | Percepção auditiva e velocidade de processamento | Cérebro |
|  | Olho de Águia | Precisão e velocidade visual | Cérebro |
|  | Ondas Sonoras | Velocidade de processamento auditivo | Cérebro |

Tabela 3.2: Nome, descrição e grupo de cada jogo (BRAINHQ, 2018)

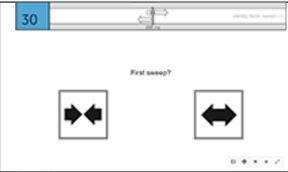
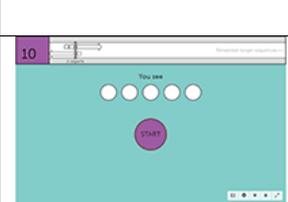
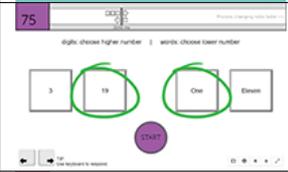
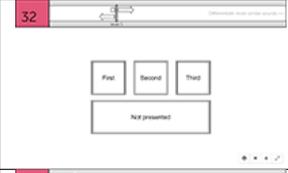
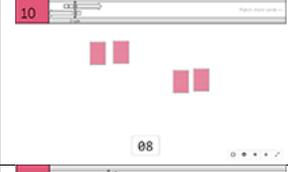
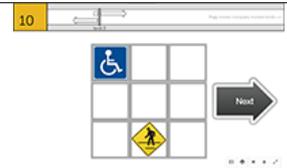
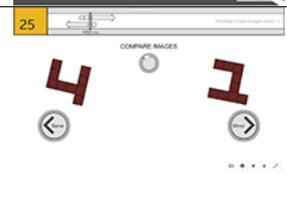
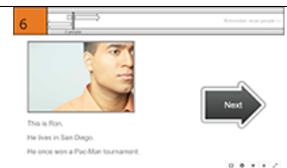
| Ilustração | Jogo | Objetivo | Grupo de Jogo |
|---|----------------------|---|---------------|
|  | Ondas Visuais | Velocidade de processamento visual | Cérebro |
|  | Ás da Audição | Aperfeiçoar a Inteligência | Inteligência |
|  | Mestre das Cartas | Estímulo à memória de trabalho; resolução de problemas | Inteligência |
|  | Jogo dos Malabares | Aprimorar a Inteligência | Inteligência |
|  | Molda Mente | Aprimora a Inteligência | Inteligência |
|  | Ouça, Ouça | Treinar a Habilidade de Ignorar Distrações | Memória |
|  | Jogo da Memória | Aprimorar a Memória | Memória |
|  | Olho da Mente | Melhorar a Memória visual, o foco e a atenção e o controle de distrações | Memória |
|  | Recuperação do Ritmo | Melhorar as habilidades de linguagem, a memória e velocidade de processamento | Memória |

Tabela 3.3: Nome, descrição e grupo de cada jogo (BRAINHQ, 2018)

| Ilustração | Jogo | Objetivo | Grupo de Jogo |
|---|-------------------|---|---------------|
|  | Estranho no Ninho | Melhorar a Memória de trabalho e varredura visual. | Memória |
|  | Pilha de Sílabas | Aprimorar a Memória | Memória |
|  | Mapa Mental | Aprimorar Memória Espacial | Orientação |
|  | Fluxo Visual | Atenção Visual e Detecção rápida de estímulos visuais | Orientação |
|  | Giro Mental | Melhorar as habilidades de rotação espacial e Criatividade | Orientação |
|  | Rumo Certo | Melhorar a Orientação, Memória Verbal, Memória Espacial | Orientação |
|  | Fotos e Fatos | Melhorar a Habilidade social | Socialização |
|  | Cara a Cara | Melhorar a Cognição social e Velocidade de processamento visual | Socialização |
|  | Reconhecimento | Melhorar Reconhecimento facial e velocidade de processamento visual | Socialização |

Apesar de todos os participantes envolvidos no treinamento cognitivo computadorizado interagirem com todos os jogos, mostrados nas tabelas 3.1, 3.2 e 3.3, cada um deles seguem uma ordem diferente de jogos em relação aos outros participantes em cada sessão do treinamento cognitivo computadorizado. Na Figura 3.3, podemos exemplificar a linha do tempo do processo de treinamento cognitivo computadorizado em que mostra, por exemplo, a interação do participante com jogos de computador de base cognitiva ao longo das 40 horas de treinamento cognitivo. Assim, impedir o desenvolvimento de doenças degenerativas, como o Alzheimer, devido ao processo de envelhecimento. Neste contexto, cada grupo de jogos traz uma série de jogos baseados em computador que são responsáveis por um tipo específico de treino e que serve para estimular uma habilidade específica, por exemplo, atenção, cognição, memória, velocidade do cérebro, estímulos sensoriais etc.

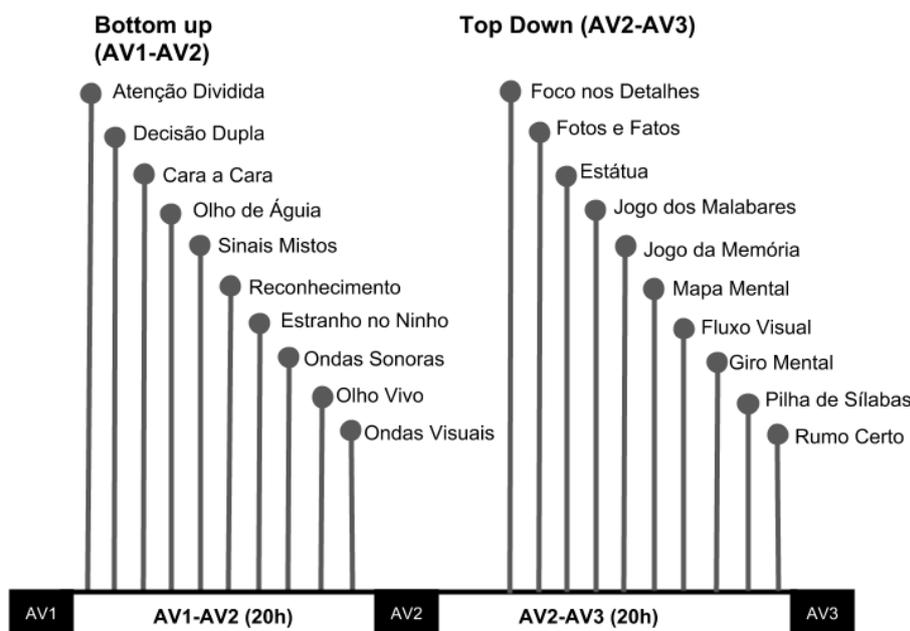


Figura 3.3: Linha do tempo de um treinamento cognitivo computadorizado com uso de jogos.

O modelo de avaliação dos participantes idosos é composto por 4 fases denominadas triagem, pré-intervenção ou Baseline (AV1), intervenção (AV2) e pós-intervenção (AV3). Na triagem, o indivíduo é avaliado para visão, audição, cognição (exame Mini-Mental), quociente de inteligência (QI), depressão e funcionalidade. Os indivíduos que foram considerados saudáveis, após a triagem, estão sujeitos a três avaliações (AVs), AV1, AV2 e AV3 nas quais são analisados os fatores de qualidade de vida, memória, velocidade de processamento, atenção / concentração, função executiva, cognição social, praxia e atividade

física. A seguir, fornecemos mais detalhes de cada fase.

3.2.1 Triagem

As atividades de triagem são prévias ao treinamento, com o intuito de verificar se os participantes estão aptos ao treinamento cognitivo computadorizado.

O indivíduo é recebido e submetido a um método de teste de acuidade visual definido por Jaeger (COLENBRANDER; RUNGE, 2007). Nesse método, o avaliador coloca um gráfico na frente do indivíduo a uma distância de 0,5 metro. Essa avaliação é considerada adequada ao indivíduo que apresentar um intervalo de 20/20 ou 20/25. Depois disso, a audição do indivíduo é medida usando uma audiometria básica, realizada com o suporte de um notebook que contém um áudio pré-gravado com configuração de 10 dB de 125 Hz. O som é reproduzido para o indivíduo em um fone de ouvido. Se o indivíduo pode ouvir o som, então é considerado apto.

O Mini-Mental (TOMBAUGH; MCINTYRE, 1992) é um teste de triagem cognitiva que avalia o estado mental do paciente. Testa superficialmente as 5 áreas da função cognitiva: orientação (dividida em 10 questões), memória imediata (dividido em 3 palavras que devem ser memorizadas pelo paciente), atenção e cálculo (executando uma operação aritmética simples), evocação em que o paciente deve reproduzir as 3 palavras memorizadas em "memória imediata" e linguagem (dividida em 6 questões). Além disso, o teste Mini-Mental tem uma pontuação de corte que deve ser maior do que 23, de modo que o paciente possa ser incluído no treinamento e, portanto, não tem indicativo de comprometimento cognitivo leve (CCL). A pontuação máxima é 30.

O teste de QI consiste em um conjunto de questões cuja complexidade aumenta ao longo do teste. As questões cobrem tópicos como ciência, história, instrumentos médicos etc. Então, uma sequência lógica de figuras geométricas (raciocínio matricial) é apresentada ao paciente e pede-se a ele que escolha, com base nessa sequência lógica, a alternativa correta entre as opções. O paciente é considerado apto se o seu QI for superior a 70. Para a análise da depressão é aplicado o teste GDS-15 (CRAEN; HEEREN; GUSSEKLOO, 2003) consistindo de 15 questões que avaliam se o paciente tem um possível estado de depressão. Se GDS-15 mostra um resultado maior que 5, será indicativo de uma possível depressão.

Finalmente, são aplicados os testes de funcionalidade KATZ (SHELKEY; WALLACE, 1999), LAWTON (LAWTON; BRODY, 1969), TIADL (OWSLEY et al., 2002) e DAFS

(MCDOUGALL et al., 2010). O teste KATZ avalia a vida diária mais simples do participante idoso. O LAWTON avalia a vida diária mais complexa, ou seja, o uso de instrumentos como o telefone, por exemplo. Esses testes são subjetivos. Os testes práticos de TIADL e DAFS também avaliam a vida diária, isto é, como os indivíduos se comunicam, como lidam com as compras e como lidam com as finanças (capacidade de lidar com o dinheiro), mas esses testes são objetivos.

Todos os participantes incluídos em nossa pesquisa não apresentaram o CCL ou outro tipo de problema que os impedissem de participar do treinamento, com base nos resultados dos testes de triagem e, portanto, foram aptos a participar do treinamento cognitivo computadorizado, foco do nosso estudo.

3.2.2 Intervenções

Depois que o indivíduo é considerado apto, ele / ela é submetida aos exames WHOQOL - BREF (POWER, 1998) (em relação à saúde e qualidade de vida) e WHOQOL-OLD (PEEL; BARTLETT; MARSHALL, 2007) (diz respeito a pensamentos e sentimentos). Ambos pertencem ao fator de qualidade de vida.

Posteriormente, o indivíduo executa o teste COGSTATE (MIELKE et al., 2015). Esse teste envolve a atividade de jogo de cartas e é subdividido em seis classificações: ONE BACK (dada uma sequência de cartas de baralho, clicar com o mouse no momento em que a carta aparece), TWO BACK (que consiste em verificar se a nova carta de baralho retirada é igual a segunda), DETECTION TASK (que consiste em verificar se a nova carta de baralho retirada é a mesma que a carta anterior, dada uma sequência de cartas), IDENTIFICATION TASK em que observa uma nova carta de baralho que aparece e a compara com duas cartas anteriores. Se a nova carta de baralho é igual em número, naipe e cor que as anteriores, o indivíduo deve clicar com o mouse; SET SHIFTING TASK (faz uma simulação para detectar o mesmo número de cartas de baralho subsequentes); e SOCIAL-EMOTIONAL (o indivíduo deve identificar a expressão facial diferente das outras apresentadas). Esses testes permitem avaliar a velocidade de processamento e a memória do indivíduo.

O próximo teste é o FLUÊNCIA VERBAL (KEMPLER et al., 1998) em que o participante deve listar o número máximo de animais em um tempo cronometrado de 1 minuto. Posteriormente, o teste RAVLT (BOONE; LU; WEN, 2005) é realizado em que o avaliador lê 15 palavras de forma pausada e, ao fim da leitura, pede ao participante que as repita. A avaliação de CAMCOG (HUPPERT et al., 1995) realiza o teste de reconhecimento em

que algumas questões são aplicadas ao indivíduo e, em seguida, o teste CAMCOG Praxia (Capacidade de realizar a parte motora em que o indivíduo irá atuar voluntariamente ou sob comando do avaliador). Então, a avaliação TRAIL MAKING (RASMUSSEN et al., 1998) é realizada por meio de dois testes: um é conectar somente pontos numéricos, em uma folha de papel (TRAIL A). Em seguida, é aplicado o teste em que o indivíduo deve conectar pontos, alternando números com letras, executado, assim como o exame TRAIL A, em uma folha de papel (TRAIL B). Ambas os exames ou testes são cronometrados.

Os exames ou testes do IPAC e TUG avaliam as atividades físicas do paciente. Por exemplo, uma das atividades físicas pertencentes ao IPAC é a atividade esportiva. O TUG refere-se à independência funcional, ou seja, ser capaz de se levantar de uma cadeira, caminhar 3 metros e não correr o risco de cair.

3.2.3 Avaliações

As avaliações avaliam os participantes antes, durante e no fim do treinamento cognitivo computadorizado. Elas são divididas em: pré-intervenção (AV1), intervenção (AV2) e pós-intervenção (AV3). Em cada uma dessas avaliações são aplicados os exames descritos na Subseção 3.2.2.

Após a triagem, os participantes são submetidos a uma primeira avaliação (AV1) ou pré-intervenção ou Baseline da AV1 (o estado atual do participante idoso antes do treinamento cognitivo computadorizado). Nela, os participantes obtêm, para cada exame ou teste associado, uma certa pontuação (Baseline da AV1). Em seguida, os participantes são divididos em duas categorias: treinamento cerebral computadorizado (treinamento Top down e Bottom up) e jogos comerciais de computador ou controle (placebo).

No grupo de treinamento Top Down, os participantes interagem com jogos cognitivos que estimulam funções executiva, de planejamento, organização, velocidade cerebral e memória nas primeiras 20 horas de treinamento cognitivo com base em computador.

No grupo de treinamento Bottom up, os participantes interagem com jogos cognitivos que estimulam funções de processamento e memória sensoriais (visão, audição, aspectos motores etc) nas primeiras 20 de treinamento cognitivo com base em computador.

Após 20 horas de treinamento cognitivo computadorizado, os participantes são reavaliados através de uma segunda avaliação (AV2) ou intervenção. Nela, os participantes obtêm para cada exame ou teste associado, uma nova pontuação. Nas 20 horas restantes de treinamento, desde a última avaliação (AV2), há uma inversão no tipo de treinamento

cognitivo: os participantes que inicialmente interagiram com jogos com uma característica mais Top down, iniciam as últimas 20 horas interagindo com jogos com uma característica mais Bottom up, da mesma forma, que aqueles que interagiram com jogos com uma característica mais Bottom up, iniciam as últimas 20 horas interagindo com jogos com uma característica mais Top down. Contudo, originalmente, os grupos são mantidos, isto é, não há inversão dos participantes em cada grupo.

Essa abordagem é necessária, pois esses grupos devem interagir com as características dos jogos (Top down e Bottom up), alternando o treinamento cognitivo, para estimular as principais funções do cérebro.

Ao fim destas 20 horas de treinamento, totalizando 40 horas, os participantes são submetidos na última intervenção (AV3), conforme observado na Figura 3.3. Nessa avaliação (AV3), os participantes idosos obtêm, para cada exame ou teste associado, uma nova pontuação.

Capítulo 4

Metodologia de Pesquisa

Para alcançar o objetivo principal da dissertação (identificação de padrões na interação de idosos com jogos cognitivos computadorizados), utilizamos a abordagem quantitativa, caracterizada como pesquisa experimental. Estudos experimentais destinam-se especificamente à análise de relações de causalidade, a partir da imposição de algum tipo de tratamento para um grupo (grupo de tratamento ou intervenção), mas não para outro grupo (grupo de controle, comparação ou placebo) (RECKER, 2013).

O método de pesquisa foi estruturado em três grandes etapas:

1. **Captura e aquisição do conhecimento:** nesta etapa buscamos compreender o universo da pesquisa em um estudo etnográfico realizado no contexto do projeto Academia do Cérebro, junto ao Serviço de Psicologia Aplicada (SPA) da PUC-Rio;
2. **Modelagem do conhecimento:** nesta etapa criamos os modelos conceitual e físico da base de dados do treinamento cognitivo computadorizado para o posterior armazenamento dos dados coletados; e aplicamos modelo de proveniência (PROV-DM) no modelo conceitual;
3. **Extração do conhecimento:** nesta etapa aplicamos diferentes técnicas para auxiliar na descoberta de padrões, como técnicas de visualização e de mineração de dados não supervisionada baseada em clusterização (k-means);

Os procedimentos metodológicos idealizados para cada uma das etapas serão detalhados nas subseções 4.1, 4.2 e 4.3, apresentadas a seguir. Na seção 4.4 será apresentado o modelo de processo da presente pesquisa.

4.1 Captura e aquisição do conhecimento

O estudo etnográfico foi realizado no período de março/2016 a dezembro/2016 nas instalações do SPA/PUC-Rio com o intuito de se ambientar no processo do treinamento cognitivo computadorizado com participantes idosos. O estudo contemplou observação dos participantes em treinamento e consultas aos especialistas do projeto.

Essa ambientação foi importante, pois facilitou e possibilitou o entendimento de todo o processo, como: quais jogos fazem parte do processo, como é a interação dos idosos com esses jogos (exercícios) e quais são os exames e as avaliações realizadas através deles.

O estudo etnográfico permitiu também que executássemos ações que garantissem a organização e a correta coleta dos dados, a criação de um modelo conceitual e, posteriormente, um modelo físico da base de dados, além de algoritmos que serviram de suporte para assegurar o correto armazenamento desses dados.

4.2 Modelagem do conhecimento

A modelagem do conhecimento foi feita a partir das informações coletadas no estudo etnográfico. Uma característica importante desta etapa foi a dificuldade de reunir os dados de treinamento, uma vez que eles estavam dispersos, em diferentes fontes. Por exemplo, as informações demográficas dos participantes (nome, idade, sexo etc) estavam organizadas em uma planilha, os dados sobre as sessões dos jogos, por sua vez, estavam disponíveis no Portal do BrainHQ¹ e os resultados dos exames, por participante, em outro conjunto de planilhas.

Após análise de todos os artefatos relacionados ao treinamento e anotações feitas no estudo etnográfico, foi criado o modelo conceitual para suporte ao treinamento cognitivo computadorizado, nomeado CogTraining-DM (Cognitive Training Data Model), representando os dados de treinamento cognitivo para idosos e sua instânciação em um banco de dados relacional.

Cabe destacar que a modelagem conceitual tem sido vista como um meio para superar os desafios que surgem frente as tentativas de projetar e desenvolver sistemas para auxiliar as pessoas em geral na sua vida cotidiana e no envelhecimento saudável (HE et al., 2008; DINOVA, 2016).

¹<https://www.brainhq.com/>

O CogTraining-DM especializa o padrão PROV-DM (detalhado na seção 2.1), portanto, ele pode ser considerado compatível com o PROV, que possibilita o registro do histórico de uma informação a partir do modelo de dados conceitual proposto.

O desenvolvimento do CogTraining-DM foi feito em três etapas: (i) Modelagem conceitual, em alto nível de abstração, das etapas das avaliações (triagem, AV1, AV2 e AV3) e os dados de seus respectivos testes previamente discutidos no capítulo 3; (ii) Instanciação do banco de dados seguindo o modelo conceitual proposto; (iii) Desenvolvimento de um algoritmo para facilitar o processo ETL (extrair, transformação e carga) das diversas planilhas e assim armazenar essas informações em tabelas do banco de dados mapeados pelo modelo PROV.

Para o projeto do CogTraining-DM, foram utilizados a UML (Unified Modeling Language) e o software Astah². A UML foi escolhida para modelagem conceitual, pois visa especificar, visualizar, projetar e documentar os artefatos de software, conforme descrito por seus criadores (BOOCH; RUMBAUGH; JACOBSON, 2005). Um trecho do CogTraining-DM é apresentado na Figura 4.1.

²<http://astah.net/>

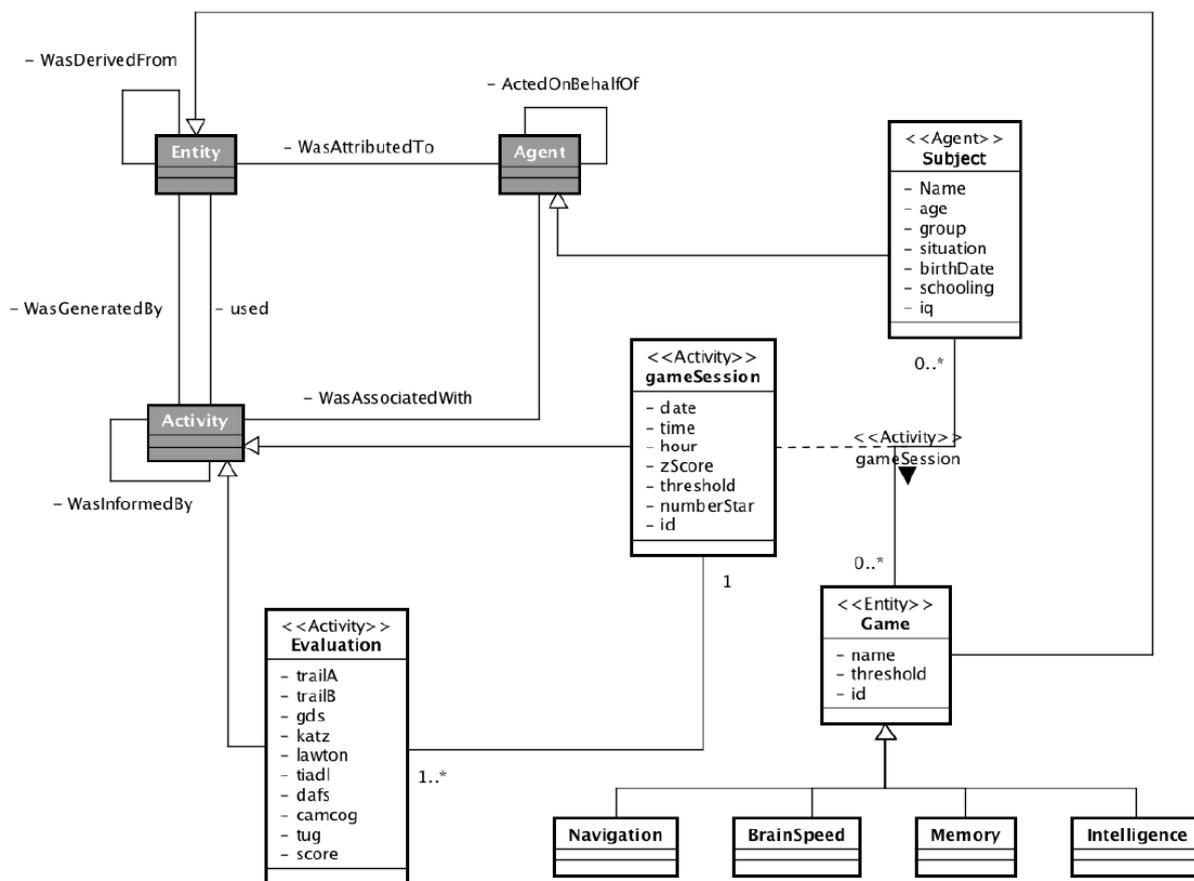


Figura 4.1: Trecho do modelo CogTraining-DM

Com a Figura 4.1, podemos ver as principais classes do modelo proposto (em branco): **Subject**, **Game**, **gameSession** e **Evaluation**. O **Subject** armazena informações relacionadas a cada assunto, como nível de QI, nome, idade etc. O **Game** armazena informações sobre o jogo sério envolvido no treinamento cognitivo. A classe associativa **gameSession** armazena informações sobre as sessões de jogo dos participantes. Cada **gameSession** está associada a um **Subject** e um **Game**. Cada **Subject** pode jogar muitas **gameSession**. A entidade **Evaluation** armazena informações sobre as avaliações realizadas (AV1, AV2 e AV3) para cada jogo. Com base nos resultados das avaliações, podemos extrair informações úteis para mais análises de dados.

Cabe ressaltar que as principais classes de CogTraining-DM (em branco) estendem uma classe do PROV-DM (em cinza escuro). Isso significa que cada classe associada ao treinamento cognitivo especializa um dos conceitos do PROV. Assim, é intuitivo e simples extrair Agentes (**Agent**), Entidades (**Entity**) e Atividade (**Activity**) do CogTraining-DM. Além disso, podemos nos beneficiar das diversas ferramentas existentes para geren-

ciar e compartilhar dados de proveniência baseados no modelo PROV.

Após a definição do CogTraining-DM, que engloba os principais conceitos do domínio, foi elaborado um projeto físico de banco de dados, baseado neste modelo conceitual, criando assim um banco de dados com o nome **Brain Academy**. O projeto deste banco de dados foi realizado por meio do mapeamento de alto nível de cada entidade, agente e atividade do modelo conceitual para uma representação em tabelas no banco de dados físico e, portanto, gerenciado por um Sistema de Gerenciamento de Banco de Dados (SGBD). Utilizamos o SGBD PostgreSQL versão 9.6³. Este Software, além de ser gratuito, é um dos SGBDs amplamente utilizados em pesquisas acadêmicas.

Dado o exposto, com o banco de dados **Brain Academy**, as tabelas e os atributos (campos ou colunas) criados no SGBD, baseados no modelo conceitual, foi possível garantir a correta distribuição e armazenamento dos dados neles e, dessa forma, gerenciados pelo aplicativo SGBD mencionado anteriormente. Com isso, esse aplicativo manterá em segurança os dados e toda a informação do treinamento cognitivo computadorizado, além dos exames e das pontuações atribuídas aos participantes que interagiram com os jogos. Além disso, evita a redundância dos dados e assegura a qualidade e confiabilidade dos mesmos.

Como dito anteriormente, o desenvolvimento de um algoritmo foi necessário para facilitar a captura dos dados dispersos em várias planilhas e, assim, extrair, transformar e carregar dados (ETL) para as tabelas do banco de dados. O design dos algoritmos seguiu os princípios e técnicas de Orientação a Objetos para facilitar a tarefa de carregamento, já que é uma tarefa trabalhosa e propensa a erros, se executada manualmente. Os algoritmos criados estão disponíveis em repositório GitHub⁴.

Após a carga dos dados em banco de dados, foi possível realizar consultas SQL e extrair os dados para análise de dados desejados. A Figura 5.2, a seguir, apresenta uma consulta que visa extrair todas as informações das avaliações (pontuações dos exames ou testes atribuídos a cada sujeito após a interação com os jogos cognitivos) realizadas sobre as sessões de jogo com os seus grupos de jogos e de todos os participantes envolvidos no treinamento cognitivo (com **status: Finished**) ao jogarem "Eye for Detail".

³<https://www.postgresql.org/>

⁴<https://github.com/UFFeScience/Cognitive-Game-Analytics>

```
SELECT *  
FROM GAME J  
INNER JOIN GROUP GJ ON J.ID_GAMEGROUP = GJ.ID  
INNER JOIN SESSION S ON J.ID = S.ID_GAME  
INNER JOIN SUBJECT P ON S.ID_SUBJECT = P.ID  
INNER JOIN EVALUATION AVP ON AVP.ID = S.ID_EVALUATION  
WHERE P.STATUS = 'Finished'  
AND S.HOUR IS NOT NULL  
AND J.NAME = 'Eye for Detail';
```

Figura 4.2: Exemplo de consulta SQL ao modelo físico criado

O propósito da consulta é fornecer informações claras e objetivas sobre um dado histórico, de um ou mais idosos que participaram do treino e que foram submetidos aos testes ou exames com ganho de pontuações a cada conclusão do treinamento cognitivo computadorizado, como indicativos de possível melhora ou piora em seu desempenho (resposta cognitiva).

O modelo conceitual CogTraining-DM permitiu a consulta e extração de dados para Análise de dados e aplicação de mineração de dados, que serão apresentados nas próximas seções.

4.3 Extração de conhecimento

A etapa de extração de conhecimento resume-se na aplicação de técnica de mineração de dados não supervisionada baseada em clusterização (k-means) e técnicas de visualização de dados. No entanto, para analisar a probabilidade de desempenho de cada um dos participantes do treinamento, foi necessário realizar o cálculo do tamanho de efeito (TDE) como parte do processo na identificação de padrões pela clusterização. Na subseção 4.3.1 apresentaremos breve explicação sobre o cálculo do TDE e na subseção 4.3.2 os procedimentos realizados para descoberta de padrões.

4.3.1 Medida de superioridade estocástica/probabilística

Na análise de dados adotamos a medida de superioridade estocástica (VARGHA; DELANEY, 2000), como uma métrica para auxiliar a mineração de dados. O trabalho de (ESPÍRITO-SANTO; DANIEL, 2015) serviu de base para a escolha da medida do tama-

nho de efeito (TDE).

Nessa métrica, consideramos X_1, X_2, \dots, X_m como uma amostra aleatória de tamanho m de valores pertencentes a X e Y_1, Y_2, \dots, Y_n como uma amostra aleatória de tamanho n de valores pertencentes a Y , independentemente da amostra de X . Como as observações X_1, X_2, \dots, X_m e Y_1, Y_2, \dots, Y_n são todas independentes em cada um (X e Y), medimos a diferença probabilística, em um intervalo $[0, 1]$, na comparação entre os scores de dois grupos, amostras ou distribuições independentes. Essa diferença é calculada com base na fórmula 4.1.

$$\hat{A}_{XY} = [\#(X_i > Y_j) + 1/2\#(X_i = Y_j)] / n \times m \quad (4.1)$$

Em que:

\hat{A} = medida de superioridade probabilística do tamanho do efeito
 $\#(X_i > Y_j)$ = número de ocorrências nas amostras do evento $X_i > Y_j$
 $\#(X_i = Y_j)$ = número de ocorrências do evento $X_i = Y_j$
 onde $i = 1, \dots, m$ e $j = 1, \dots, n$
 m = tamanho da amostra de X
 n = tamanho da amostra de Y

Observamos que o símbolo $\#$ se refere a função contagem, X e Y são vetores que contêm scores para dois grupos. Esses scores são comparados entre os grupos em todas as combinações par a par, e os empates são multiplicados por 0,5. Caso haja igualdade probabilística ($\hat{A}_{XY} = .5$), os scores entre os grupos são iguais e, portanto, não há diferença entre esses grupos. Essa igualdade probabilística é equivalente à identidade 4.2.

$$P(X > Y) = P(X < Y) \quad (4.2)$$

É mostrado, através de um exemplo, como se dá o cálculo da medida de superioridade probabilística do tamanho do efeito em que comparou dois grupos fictícios e independentes representados pelos vetores X e Y (RUSCIO; MULLEN, 2012). Nesse exemplo, foi considerado um tamanho de amostras pequenas ($n = m = 15$) e com dados hipotéticos em que pegou membros pertencentes do grupo tratamento ou intervenção (X) e pertencentes do grupo controle, comparação ou placebo (Y). Nesse cenário, considerou-se como melhor saúde classificações ou pontuações mais altas:

$$X = \{6, 7, 8, 7, 9, 6, 5, 4, 7, 8, 7, 6, 9, 5, 4\}$$

$$Y = \{4, 3, 5, 3, 6, 2, 2, 1, 6, 7, 4, 3, 2, 4, 3\}$$

Com base nesses vetores de exemplo, o cálculo da estimativa A se dá iniciando com o valor $x_1 = 6$ e o compara com cada valor do vetor y , produzindo 12 instâncias em que $x_1 > y_i$ e em 2 empates. Logo, inicialmente $\hat{A}_1 = 12 + 1/2 \times (2) = 13$. Esse processo se repete com cada pontuação do vetor x em comparação com todas as pontuações de y . Nesse contexto, é somado cada \hat{A} ($\hat{A}_1 + \hat{A}_2 + \hat{A}_3 + \dots + \hat{A}_{15}$) parcial calculado e o total dessa soma é dividido pelo produto do total de cada amostra ($n \times m$).

Com base no cálculo apresentado, para o exemplo em questão, é totalizado uma estimativa estocástica ou probabilística de $\hat{A} = 199/225 = 0,884$ ou 88,4% em que mostra que a chance de que uma pontuação aleatória pertencente a variável X ser maior que uma pontuação aleatória pertencente a Y , é aproximadamente 0,884 ou 88,4%.

4.3.2 Mineração de dados para descoberta de padrões

Para compreendermos os valores atribuídos aos exames na avaliação dos participantes, pré e pós treino, e, dessa forma, entender se os indivíduos progrediram ou não após às 20 horas de treinamento (pós treino - AV2) desde o seu baseline (pré treino - AV1), foi preciso coletar as unidades desses valores, conforme apresentado na tabela 4.1.

Tabela 4.1: Exames e unidades de medida relacionada

| Exame | Unidade de medida relacionada |
|---|-------------------------------|
| Two Back, CR, HITS, CAMCOG_REC, gds, verbal fluency (fluência), camcog_praxia, Set Shifting Task, Social-Emotional Cognition Task, dafs, lawton, katz | Pontos |
| trail_b, trail_a, Detection Task, Identification Task, tiadl, One Back | Segundos |

Com a ajuda da equipe do projeto Academia do Cérebro, categorizamos cada exame que avalia e pontua os participantes após cada etapa do treinamento cognitivo computadorizado, dentro de grupos de habilidades de exames e recalculamos o TDE com base nesses grupos, como parte da análise de dados no processo de mineração de dados. A separação dos exames por grupos de habilidades é importante, porque permite uma análise mais focada em grupos de exames com características específicas. Essa categorização permitiu

que fizéssemos as análises através da aplicação de técnicas de mineração de dados, porém com base em grupos de habilidades e não apenas em exames individuais.

A Tabela 4.2 apresenta os grupos de habilidades (categorias) definidos pela equipe do projeto, sua descrição e os exames associados.

Tabela 4.2: Grupos de habilidades e exames associados

| Grupo | Descrição | Exames associados |
|-----------------------------|--|--|
| Memória | Relacionados à capacidade de memorização do indivíduo | Two Back, One Back, CR, HITS, CAMCOG_REC |
| Cognição Social | Relacionados à capacidade do indivíduo de perceber mudanças ligadas a emoção | Social-Emotional Cognition Task |
| Função Executiva | Relacionados à capacidade do sujeito de manter a concentração e coordenação motora, percebendo a mudança de estados | trail_b, Set Shifting Task |
| Depressão | Relacionado à motivação e ao estado depressivo dos indivíduos | gds |
| Atenção | Relacionados à capacidade do sujeito de se manter atento em meio a distrações | trail_a, Identification Task |
| Linguagem | Relacionados à capacidade do indivíduo de se expressar verbalmente e por meio de movimentos físicos imaginários com as mãos, simulando certas ações com certos objetos | verbal fluency (fluência), camcog_praxia |
| Velocidade de Processamento | Relacionado à capacidade do indivíduo de tomar decisões com base em um tempo de resposta | Detection Task |
| Funcionalidade | Relacionados à capacidade do participante em manter a concentração ou o foco e habilidade motora ao executar determinadas atividades ou tarefas do dia-a-dia | dafs, lawton, katz, tiadl |

A mineração de dados é composta de aprendizado supervisionado e não supervisionado. Em nossa análise aplicamos o aprendizado não supervisionado, pois é o método em que identifica como os objetos ou observações podem ser agrupados em classes ou clusters, baseados nas variáveis ou atributos associados aos objetos. Com o aprendizado não supervisionado e com base na natureza dos nossos dados, o algoritmo que melhor atendeu e contribuiu para a nossa análise, foi o algoritmo K-Means (JAIN; MURTY; FLYNN, 1999), pois o mesmo é capaz de fazer agrupamentos/partições dos dados em grupos similares, permitindo a tomada de decisão por profissionais da área fim.

Esse algoritmo tem como objetivo criar partições não aninhadas e não sobrepostas dos objetos ou ocorrências com os seus atributos associados, no dataset, com base no cálculo de alguma função de distância, por exemplo, distância Euclidiana que mede a similiaridade / dissimilaridade entre essas ocorrências. Com isso, quanto menor a distância calculada, maior é a similiaridade desses objetos e, dessa forma, são agrupados ou clusterizados nos mesmos grupos ou clusters.

Antes de executarmos o algoritmo K-Means, selecionamos os dados necessários à construção do nosso dataset ou conjunto de dados. Alguns desses dados consistem de exames que são medidos com base em pontuação e outros exames que são medidos com base em tempo de resposta. Isso gerou um problema de se ter unidades de medidas distintas, pois o grupo habilidade memória possui esses tipos de exames que têm unidades diferentes. O mesmo ocorreu com exames dos grupos funcionalidade, atenção e velocidade de processamento.

Para resolver esse problema, foi necessário normalizar os dados afim de igualar essas unidades. Com isso, aplicamos a fórmula de normalização Z (z-score).

Após a normalização das unidades de medida, construímos dois datasets, um deles relacionado aos exames pertencentes ao grupo habilidade memória e o outro aos exames pertencentes aos grupos habilidades memória, funcionalidade, atenção e velocidade de processamento.

Em ambos os datasets consideramos as seguintes *features* ou atributos comuns ou gerais:

- **Gender:** gênero dos participantes.
- **Age:** idade dos participantes.
- **YearsEducation:** se refere ao tempo de escolaridade dos participante.
- **IQ:** QI (quociente de inteligência).
- **UseMedicine:** atributo binário que se refere ao uso ou não de algum medicamento por parte dos indivíduos.
- **UseLegalDrugs:** atributo binário que se refere ao uso ou não de alguma droga lícita por parte dos indivíduos.
- **UseIllegalDrugs:** atributo binário que se refere ao uso ou não de alguma droga ilícita por parte dos indivíduos.

- **Group**: se refere aos grupos BU e TD.
- **LIKELIHOOD**: medida de superioridade probabilístico do TDE em %.

Especificamente para o conjunto de dados referente aos exames do grupo habilidade memória, consideramos as seguintes features ou atributos:

- **TWO_BACK**: exame baseado em pontuação.
- **ONE_BACK**: exame baseado em tempo de resposta.
- **CR**: exame baseado em pontuação.
- **HITS**: exame baseado em pontuação.
- **CAMCOG_REC**: exame baseado em pontuação.

No conjunto de dados referente aos exames dos grupos habilidade memória (os mesmos atributos apresentados anteriormente), funcionalidade, atenção e velocidade de processamento, consideramos as seguintes features ou atributos:

- **KATZ**: exame baseado em pontuação.
- **LAWTON**: exame baseado em pontuação.
- **TIADL**: exame baseado em tempo de resposta.
- **DAFS**: exame baseado em pontuação.
- **TRAIL_A**: exame baseado em tempo de resposta.
- **IDNTSK**: exame baseado em tempo de resposta.
- **DETECTIONTSK**: exame baseado em tempo de resposta.

Utilizamos a ferramenta de análise de dados **Orange Workflow Engine** versão 2.7 para executar o algoritmo de clusterização não supervisionado K-Means com base no conjunto de dados dos exames dos grupos de habilidade.

Com a execução desse algoritmo no conjunto de dados dos exames do grupo de habilidade memória, consideramos como quantidade de divisões K igual a 3, igual a 5 e igual a 7 grupos ou clusters (K centróides). Já para o conjunto de dados dos exames dos

grupos de habilidades memória, funcionalidade, atenção e velocidade de processamento, consideramos como quantidade de divisões K igual a 3 e igual a 5.

No conjunto de dados relativo ao grupo memória, o K-means foi executado considerando apenas os atributos referentes a pontuação dos exames normalizada, para a clusterização. Já no grupo memória, funcionalidade, atenção e velocidade de processamento, além de considerar a pontuação dos exames normalizada, consideramos também o atributo "Group", para melhor visualização dos resultados por grupos (TD, BU). Toda execução do K-means foi realizada com suporte do software Orange Workflow Engine, escolhido devido nosso conhecimento prévio e experiência no uso da ferramenta.

Uma vez gerados esses clusters, cada participante ou objeto foi mapeado para o seu respectivo cluster ou grupo, com base no cálculo de alguma função de distância, por exemplo, distância Euclidiana que mede a similaridade entre essas ocorrências. Isso pode ser verificado, por exemplo, em um trecho dos dados do grupo habilidade memória, como apresentados na Figura 4.3.

| TWOB | ONB | CR | HITS | CAMCOG_REC | CLUSTER | GRUPO | Participante |
|--------|--------|--------|--------|------------|---------|-----------|--------------|
| 0.391 | 0.391 | -1.781 | 0.608 | 0.391 | C1 | Bottom_up | 3 |
| 0.739 | 0.339 | -1.757 | 0.240 | 0.439 | C1 | Bottom_up | 13 |
| 1.706 | -0.426 | -0.853 | 0.000 | -0.426 | C1 | Bottom_up | 26 |
| 1.763 | -0.287 | -0.697 | -0.287 | -0.492 | C1 | Bottom_up | 32 |
| 1.778 | -0.603 | -0.444 | -0.286 | -0.444 | C1 | Bottom_up | 41 |
| 1.447 | 0.606 | -0.404 | -0.909 | -0.741 | C1 | Bottom_up | 44 |
| 0.000 | -0.943 | -0.943 | 1.414 | 0.471 | C1 | Bottom_up | 62 |
| 1.643 | -0.183 | -0.183 | -0.183 | -1.095 | C1 | Bottom_up | 111 |
| 1.565 | -0.671 | 0.447 | -0.671 | -0.671 | C1 | Top_down | 22 |
| 1.785 | -0.484 | -0.333 | -0.484 | -0.484 | C1 | Top_down | 50 |
| 1.526 | 0.381 | -0.953 | -0.191 | -0.763 | C1 | Top_down | 36 |
| 1.334 | -1.231 | -0.718 | 0.308 | 0.308 | C1 | Top_down | 55 |
| 0.554 | 0.554 | -1.753 | 0.554 | 0.092 | C1 | Top_down | 95 |
| 1.783 | -0.582 | -0.400 | -0.400 | -0.400 | C1 | Top_down | 112 |
| 1.059 | -1.088 | 1.059 | -0.658 | -0.372 | C2 | Bottom_up | 34 |
| -1.565 | -0.447 | 0.671 | 0.671 | 0.671 | C2 | Bottom_up | 39 |

Figura 4.3: Trecho dos dados do grupo habilidade memória

Desses clusters, os que apresentaram um melhor resultado, considerando o tamanho da amostra ($n = 35$) e, além disso, considerando que em cada cluster há um número relevante de objetos ou observações a analisar, dada a similaridade entre eles, foram as K partições iguais a 3 para os exames do grupo habilidade memória e iguais a 3 para os exames dos grupos habilidades memória, funcionalidade, atenção e velocidade de processamento. Embora não tenham sido considerados na análise, os cluster gerados para $K=5$ e $K=7$,

bem como as tabelas e gráficos de radar com valores obtidos podem ser consultados nos apêndices A e B, respectivamente.

Apesar do uso de 35 amostras ter gerado resultados relevantes, em técnicas de mineração de dados quanto maior o número de amostras, maiores são as possibilidades de particionamento e conseqüentemente podemos garantir melhor distribuição dos dados por grupos ou clusters. Como não foi possível obter mais amostras, devido a baixo número de voluntários, optamos por incluir o grupo de controle em uma nova etapa de clusterização.

Essa inserção foi importante para permitir melhor entendimento das diferentes naturezas dos grupos (top down, bottom up e controle) e assim extrair algum padrão de apoio aos especialistas na verificação das diferenças de interação dos participantes idosos com jogos cognitivos computadorizados e jogos comerciais, com base nas pontuações e tempos de resposta dos exames.

Com isso, a mineração de dados foi realizada em duas etapas: mineração de dados com 35 amostras do grupo intervenção (BU e TD) e mineração de dados com 51 amostras (35 de intervenção + 16 de controle).

Na segunda etapa (mineração de dados com 51 amostras), foram necessários ajustes nas *features* do dataset. Os atributos gerais passaram a contar com o valor "controle" no atributo "Group", como pode ser observado na listagem a seguir:

- **Gender:** gênero dos participantes.
- **Age:** idade dos participantes.
- **YearsEducation:** se refere ao tempo de escolaridade dos participante.
- **IQ:** QI (quociente de inteligência).
- **UseMedicine:** atributo binário que se refere ao uso ou não de algum medicamento por parte dos indivíduos.
- **UseLegalDrugs:** atributo binário que se refere ao uso ou não de alguma droga lícita por parte dos indivíduos.
- **UseIllegalDrugs:** atributo binário que se refere ao uso ou não de alguma droga ilícita por parte dos indivíduos.
- **Group:** se refere aos grupos BU, TD e controle.

- **LIKELIHOOD**: medida de superioridade probabilístico do TDE em %.

A segunda etapa foi realizada após apresentação dos resultados da primeira a um pesquisador da área médica, que sugeriu outros ajustes no dataset, com intuito de melhorar a qualidade da análise. Uma dessas sugestões foi analisar o resultado do exame TIADL a partir das atividades que o contemplam isoladamente (cinco, no total), e não pelo resultado do exame como um todo. Tal abordagem justifica-se por existir variação de desempenho por tempo de resposta do participante ao executar as atividades do TIADL, que podem influenciar no resultado do exame como um todo. A seguir, listamos as cinco atividades que pertencem ao exame:

- **TIADL_COMUNIC**: Avalia a habilidade de comunicação (encontrar o número de sua casa em uma agenda telefônica)
- **TIADL_FIN**: Avalia a habilidade para lidar com dinheiro (dar troco)
- **TIADL_COMP**: Avalia habilidade de fazer compras (localizar itens de supermercados)
- **TIADL_COMIDA**: Avalia habilidade de compreender rótulos (ler e compreender ingredientes em latas de comida)
- **TIADL_MED**: Avalia habilidade de compreender embalagens de medicamentos (ler e compreender caixas de remédio)

Além disso, como não houve variação significativa das pontuações entre os exames DAFS, KATZ e LAWTON (do grupo habilidade funcionalidade) entre as avaliações base-line (AV1) e AV2, na mineração de dados com 35 amostras, o pesquisador sugeriu que os mesmos fossem retirados do dataset, o que também contribuiu para a melhor qualidade da análise.

Dado o exposto, para a mineração de dados com 51 amostras, reestruturamos o nosso dataset referente aos exames dos grupos habilidade memória, funcionalidade, atenção e velocidade de processamento, considerando as seguintes features ou atributos:

- **TWO_BACK**: exame baseado em pontuação.
- **ONE_BACK**: exame baseado em tempo de resposta.
- **CR**: exame baseado em pontuação.

- **HITS**: exame baseado em pontuação.
- **CAMCOG_REC**: exame baseado em pontuação.
- **TIADL_COMUNIC**: exame baseado em tempo de resposta.
- **TIADL_FIN**: exame baseado em tempo de resposta.
- **TIADL_COMP**: exame baseado em tempo de resposta.
- **TIADL_COMIDA**: exame baseado em tempo de resposta.
- **TIADL_MED**: exame baseado em tempo de resposta.
- **TRAIL_A**: exame baseado em tempo de resposta.
- **IDNTSK**: exame baseado em tempo de resposta.
- **DETECTIONTSK**: exame baseado em tempo de resposta.

Não houve alteração nas *features* do dataset referente aos exames dos grupos habilidade memória.

Neste novo cenário, os clusters que apresentaram um melhor resultado, considerando o tamanho da amostra ($n = 51$) e um número relevante de objetos ou observações a analisar em cada cluster foram as K partições iguais a 4 para os exames do grupo habilidade memória e iguais a 4 para os exames dos grupos habilidades memória, funcionalidade, atenção e velocidade de processamento.

Como técnica de visualização foi utilizado o gráfico radar. A escolha deste gráfico justifica-se pelo mesmo permitir uma análise visual se, de fato, houve ou não evolução ou progresso dos participantes ao longo do tempo no pós treino (após 20 horas) em comparação com o seu pré treino (baseline - AV1). Com isso, foi possível definir alguns critérios, como: para exames baseados ou medidos em pontos, o desempenho do participantes foi ilustrado com a linha laranja representada pela avaliação AV2 sobre a linha azul representada pela avaliação AV1 ($AV2 = AV1$) e linha AV2 maior ou acima da linha AV1 ($AV2 > AV1$) em que significa que para esses participantes houve um progresso em sua resposta cognitiva. A figura 4.4 ilustra o gráfico radar de um participante. Para os exames baseados em tempo (medidos em segundos), a verificação das linhas AV2 e AV1 se dá de forma oposta aos exames medidos por pontos, pois quanto menor o tempo, melhor o resultado.

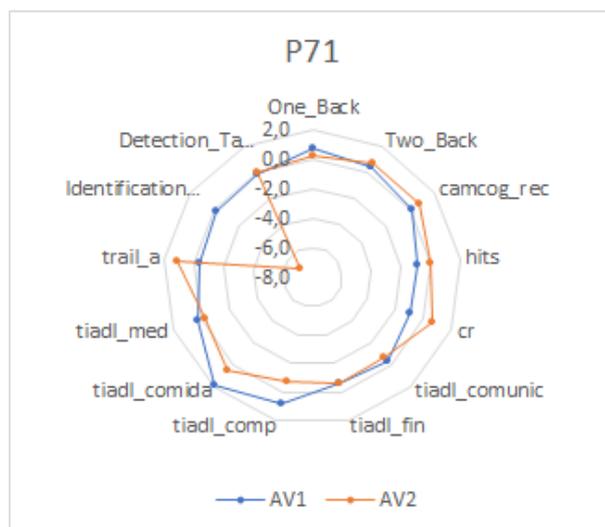


Figura 4.4: Exemplo de gráfico radar de um dos participantes do treinamento.

Posteriormente foram criadas tabelas referentes a clusterização, com base na análise dos gráficos radar dos participantes envolvidos no treinamento. A análise dos gráficos e tabelas associados aos clusters nos auxiliaram a observar e encontrar algum padrão de forma mais clara. Os resultados de ambas as etapas da análise da mineração de dados (com 35 e 51 amostras) serão apresentados no próximo capítulo.

4.4 Modelo do processo da pesquisa

Para melhor entendimento e reprodutibilidade da presente pesquisa foi realizado um mapeamento dos processos envolvidos na extração de padrões de interação de idosos com jogos cognitivos computadorizados. Tal mapeamento foi feito em notação BPMN (*Business Process Model and Notation*, em português Notação de Modelagem de Processos de Negócio) com apoio do software Bizagi⁵,

A Figura 4.5 ilustra as três principais etapas do processo de pesquisa (subprocessos): "Adquirir o conhecimento" (seção 4.1), "Modelar o conhecimento" (seção 4.2) e "Extraair o conhecimento" (seção 4.3). As etapas desses subprocessos são apresentadas nas Figuras 4.6, 4.7 e 4.8.

⁵<https://www.bizagi.com/pt>

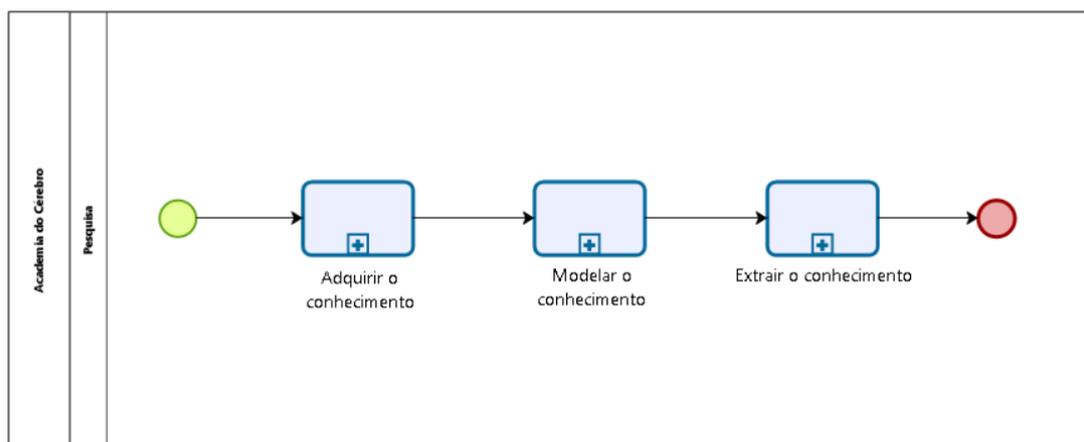


Figura 4.5: Mapa do processo da pesquisa em notação BPMN

A Figura 4.6 traz as etapas, atividades ou tarefas relacionadas a "Adquirir o conhecimento", que visa principalmente armazenar e organizar dados pessoais e histórico médico dos participantes e do seu desempenho no treinamento. Tarefas de executar registro dos dados em planilhas eletrônicas e a consulta desses dados nessas planilhas, são ambas realizadas pela equipe médica. Além disso, é executada a tarefa de organizar os dados pelo profissional da área de TI e pesquisador colaborador neste projeto. Tais atividades são resumidas a seguir:

1. **Registrar dados em planilhas eletrônicas:** Nessa etapa, são registrados dados dos participantes e do treinamento pré e pós treino coletados pela equipe médica, no momento da avaliação dos participantes, por meio de exames ou testes em planilhas eletrônicas, distribuídas em diretórios na nuvem (com software Dropbox). Os processos de "participante" e "treinamento cognitivo computadorizado com idosos", são considerados "caixa preta", uma vez desconhecemos detalhes da execução dos mesmos.
2. **Consultar dados:** Após registrar os dados nessas planilhas, a equipe médica realiza a consulta dessas informações referentes as avaliações dos participantes.
3. **Organizar os dados em banco de dados:** Como o registro dos dados em planilhas eletrônicas gera um problema de segurança, redundância de dados etc, foi necessário que planejássemos a organização (centralização) desses dados em um banco de dados gerenciado por um SGBD. Com isso, a consulta aos dados ficou mais fácil, garantindo segurança e não redundância aos dados.

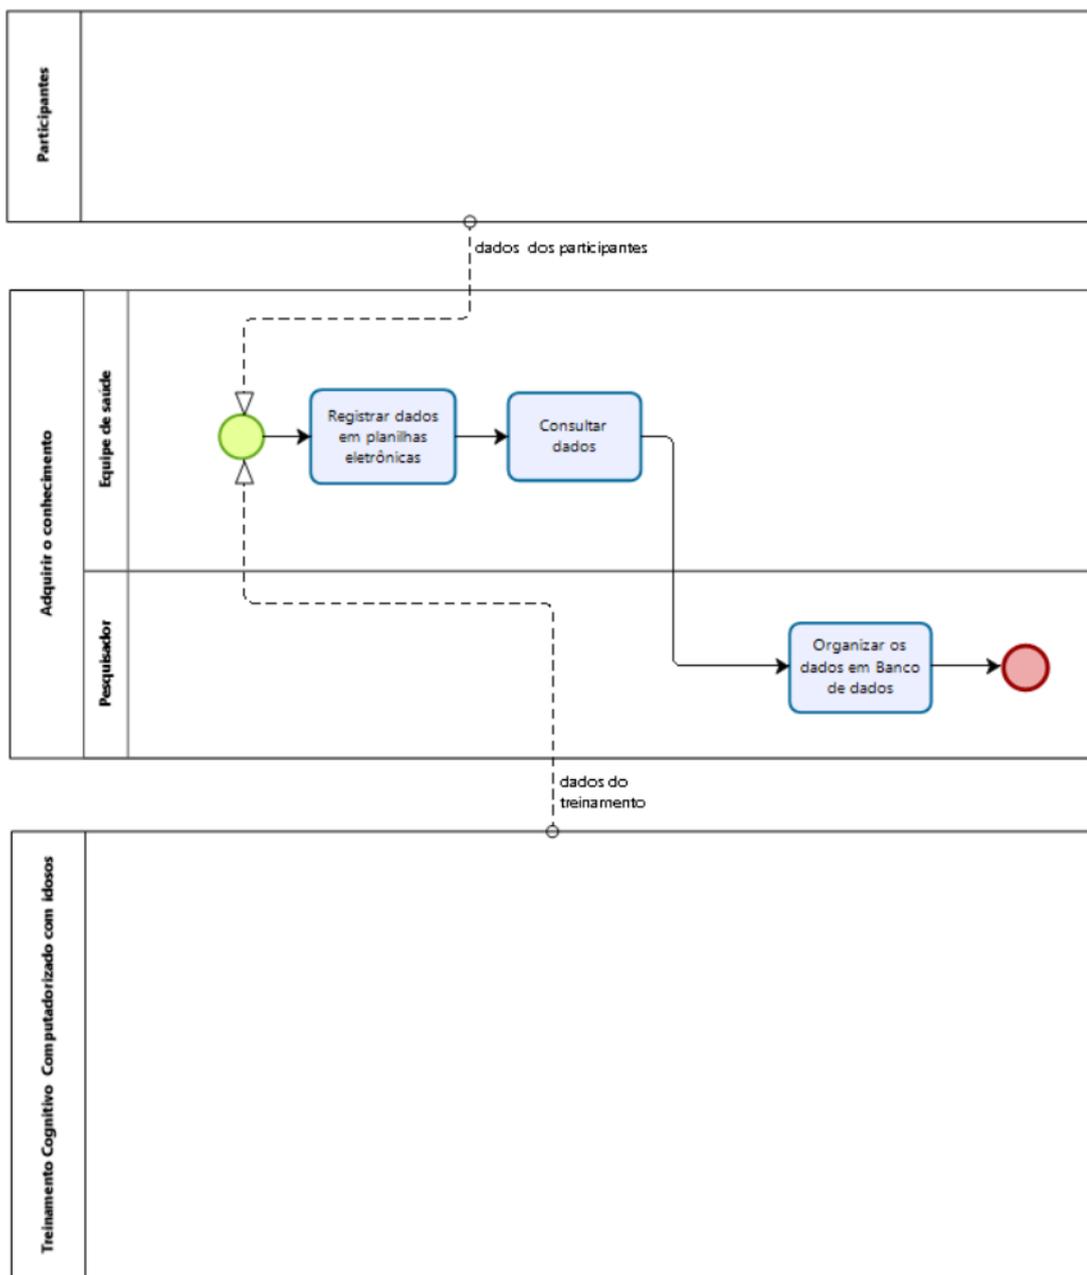


Figura 4.6: Mapa da atividade "Adquirir o conhecimento" em notação BPMN.

A Figura 4.7 ilustra as etapas relacionadas a "Modelar o conhecimento" que visa executar as atividades de construção de um modelo conceitual e de um banco de dados, além da instanciação dos dados nesse banco. Em resumo:

1. **Construir modelo conceitual de proveniência de dados com o PROV-DM da W3C:** Nessa atividade, criamos um modelo conceitual com o PROV-DM (vide seção 4.2) mapeando as entidades relacionadas ao treinamento cognitivo computadorizado.

2. **Construir banco de dados relacional:** A partir da construção do modelo conceitual de proveniência, construímos o banco de dados (**Brain Academy**), tabelas e atributos ligados ao treinamento.
3. **Instanciar os dados no banco de dados:** Com o banco de dados criado, os dados foram instanciados e armazenados nas tabelas.

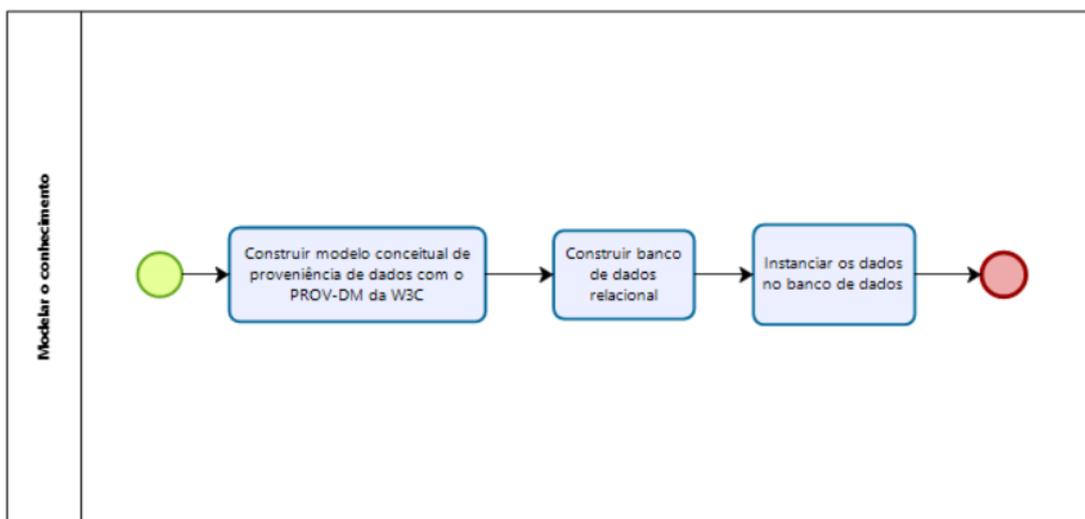


Figura 4.7: Mapa da atividade "Modelar o conhecimento" em notação BPMN

A Figura 4.8 mostra as etapas relacionadas a "Extrair o conhecimento" que visa executar as atividades que auxiliam à identificação de padrões. Em resumo:

1. **Extrair dados por meio de consulta ao banco de dados:** Nessa etapa executamos uma consulta SQL para a extração dos dados ligados ao treinamento cognitivo computadorizado.
2. **Selecionar variáveis da base de dados:** A partir da consulta aos dados e dos atributos retornados foram escolhidas variáveis (atributos) previamente indicados pela equipe de saúde as quais poderiam ter influência no desempenho do treinamento por parte dos participantes.
3. **Realizar análise de dados:** Com as variáveis selecionadas na etapa anterior realizamos a análise por meio do cálculo probabilístico em percentual do tamanho de efeito (conforme Subseção 4.3.1) que foi importante como parte do processo de extração do conhecimento, pois possibilitou verificar o desempenho dos participantes dos grupos intervenção e controle e assim selecionar aquelas variáveis que tem maior

impacto no treinamento. Nessa mesma atividade, há um gateway direcionador do tipo "OU exclusivo" que indica que se deve executar novamente a tarefa de selecionar variáveis, caso as variáveis eleitas não sejam adequadas, ou seja, não apresentem um tamanho de efeito relevante para a extração de padrão pretendida.

4. **Criar o conjunto de dados (dataset):** Nessa etapa, criamos o sub-conjunto dos dados necessários ao processo de clusterização.
5. **Aplicar técnicas de visualização de dados:** No intuito de facilitar a compreensão dos dados e verificar o desempenho ou progresso dos participantes ao longo do treino de 20h, aplicamos técnica de visualização com uso de gráficos radar.
6. **Aplicar clusterização nos dados:** Nessa atividade, aplicamos a clusterização nos dados com algoritmo não supervisionado K-Means (Subseção 4.3.2).

Vale ressaltar que todo este processo de extrair conhecimento foi realizado diversas vezes com diferentes combinações de atributos conforme discutido no Capítulo 5 de Resultados Experimentais.

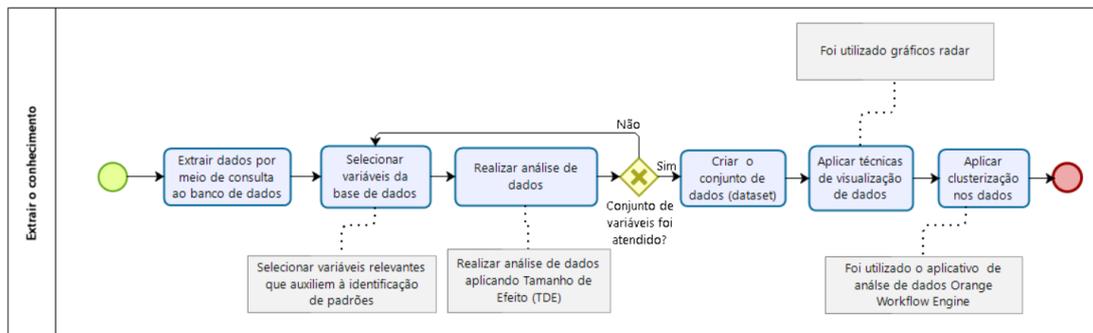


Figura 4.8: Mapa da atividade "Extrair o conhecimento" em notação BPMN.

Capítulo 5

Resultados Experimentais

5.1 Mineração de dados com 35 amostras do grupo intervenção

A primeira questão *Q1: Como os scores e tempos dos exames de cada participante evoluem ao longo do treinamento?* não foi respondida para o conjunto de amostras ($n = 35$), pois com esse quantitativo de amostras maior ficaria difícil analisar os padrões de cada participante, então, optamos por utilizar técnicas de mineração de dados, que poderiam nos levar a um análise de padrões mais eficaz.

Para apoiar a resposta da segunda questão: “*Q2: Quais são os padrões observados, que demonstram a melhora de habilidades de memória de idosos, quando submetidos a jogos cognitivos computadorizados?*”, analisamos primeiramente a Figura 5.1, que mostra uma projeção dos clusters gerados para o grupo habilidade memória da avaliação pós treinamento cognitivo computadorizado ao longo das 20 horas, considerando todos os participantes (ou objetos).

Na Figura 5.1 podemos observar uma divisão de $K = 3$ clusters e a distribuição dos objetos similares em seus respectivos clusters. Com esse mapeamento, conseguimos organizar, para cada cluster, os gráficos radar gerados por participante. Esses gráficos mostram os desempenhos similares dos participantes a partir da baseline AV1 até a avaliação AV2.

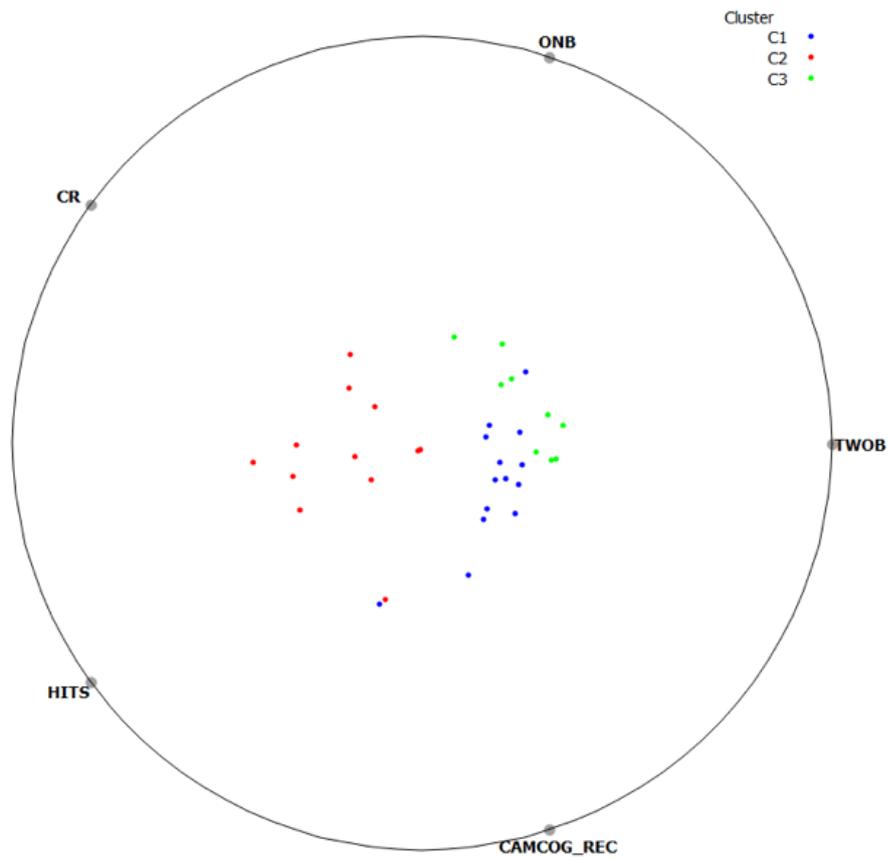


Figura 5.1: Clusters gerados para os exames do grupo memória, considerando $K=3$

Os gráficos radar gerados para os clusters C1, C2 e C3 do grupo habilidade memória são mostrados nas Figuras 5.2, 5.3 e 5.4. Nesses gráficos, podemos verificar que seus eixos ou vértices se referem aos exames ou testes que compõem esse grupo habilidade.

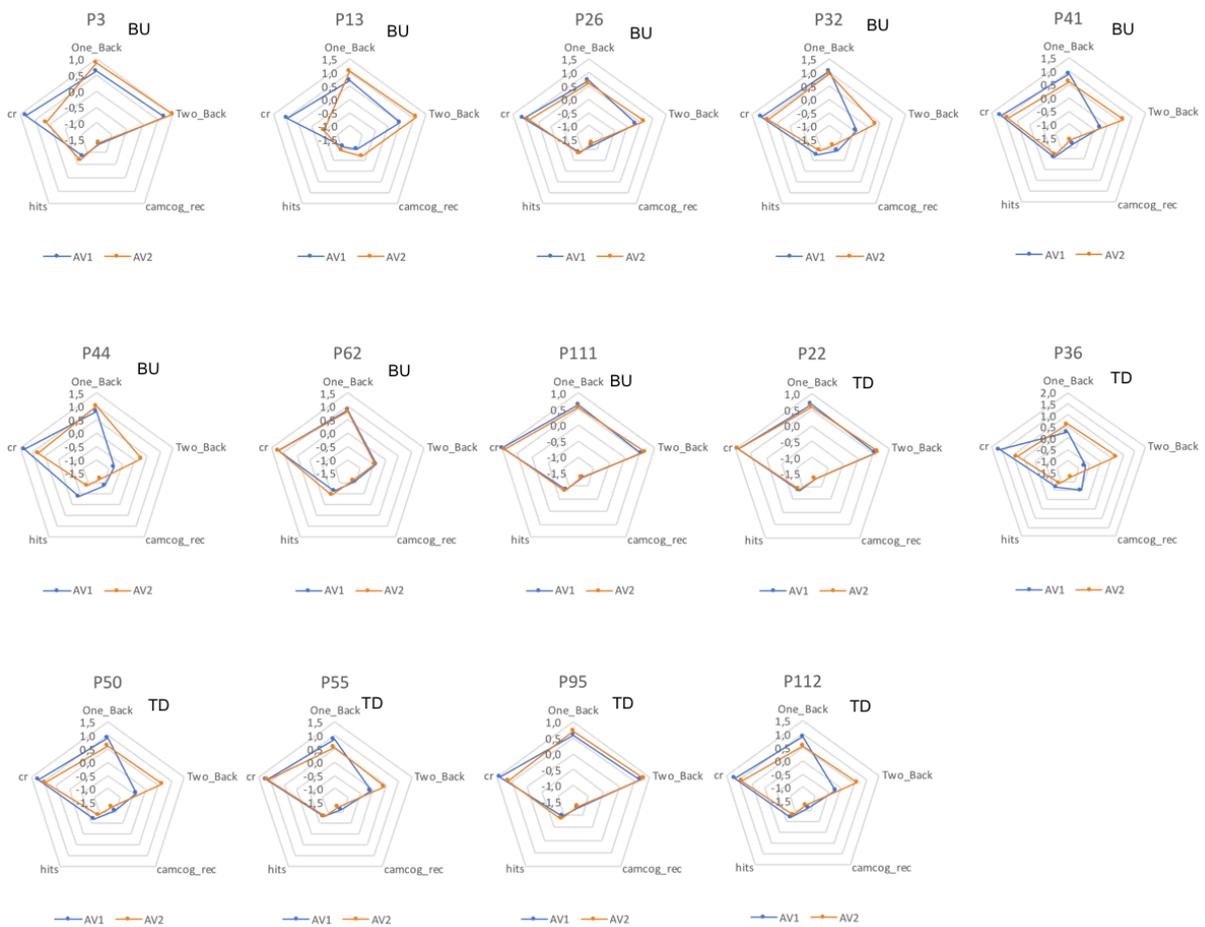


Figura 5.2: Gráficos radar de cada participantes do cluster C1 e $K=3$ (com 35 amostras). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja)

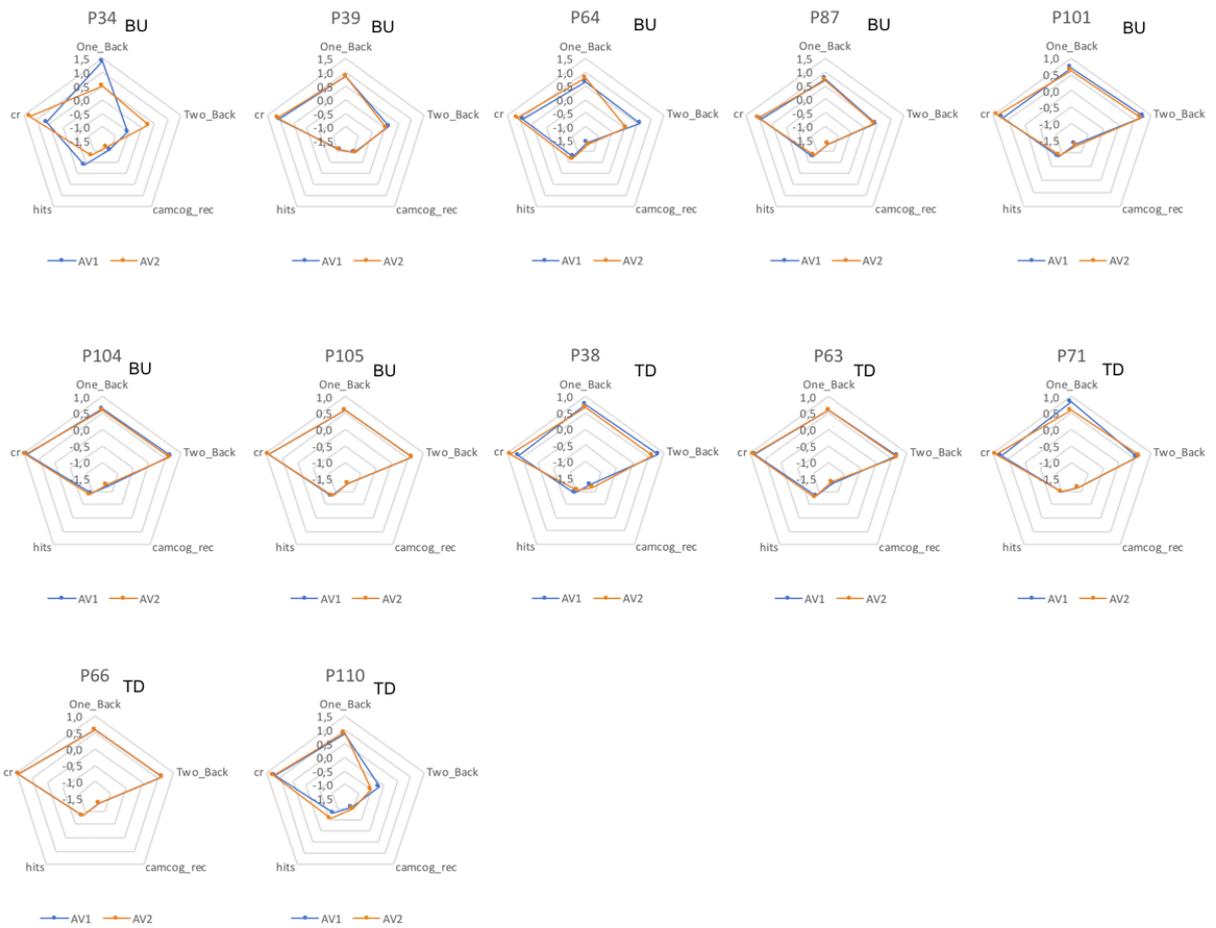


Figura 5.3: Gráficos radar de cada participante do cluster C2 e $K=3$ (com 35 amostras). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja)

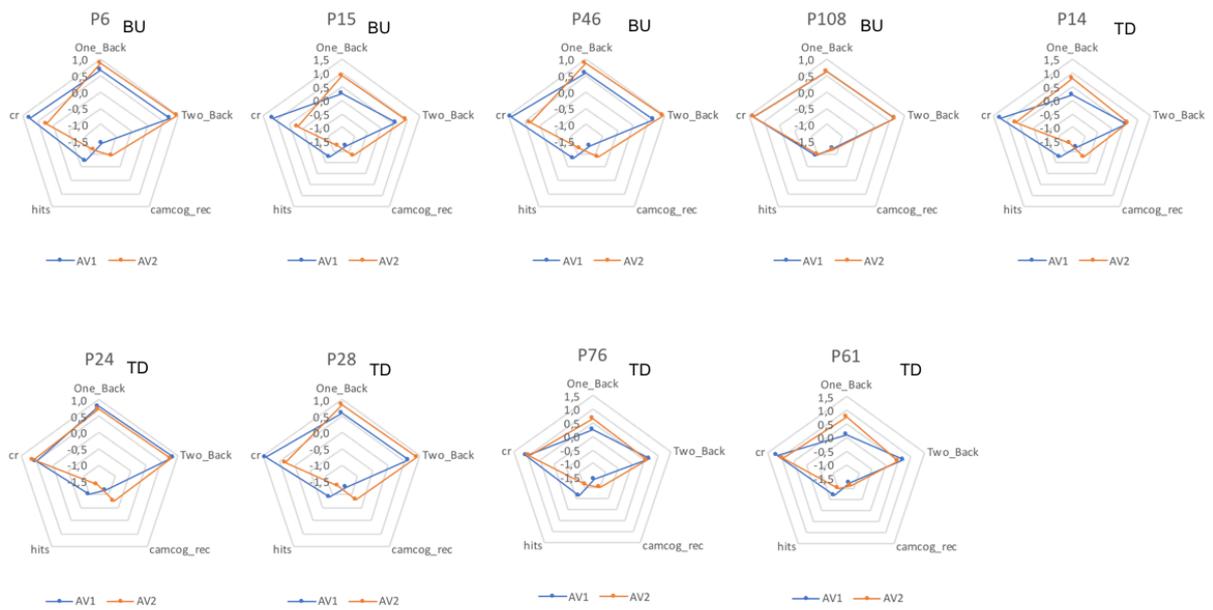


Figura 5.4: Gráficos radar de cada participante do cluster C3 e $K=3$ (com 35 amostras). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja)

Após essa distribuição dos gráficos radar por cluster, extraímos visualmente as informações de cada exame, contabilizando - para cada participante - as situações em que os resultados foram melhores ou piores, determinando desta forma as categorias: **Melhorou** ou **Piorou**. Os resultados obtidos para cada exame, por cluster, foram organizados em tabelas, para apoiar a extração de algum padrão.

As Tabelas 5.1, 5.2 e 5.3 apresentam tais resultados e foram estruturadas em cinco colunas, a saber:

- **Exame**, contendo o nome do exame em questão
- **Padrão**, com o resultado do padrão obtido (representado pelas categorias melhorou ou piorou)
- **Relação N/T**, que indica a relação entre o número de participantes que apresentaram melhoria (ou não) e o total de participantes
- **%**, contendo o percentual de cobertura
- **Participantes (Abordagem)**, onde são identificados os participantes que apresentaram o comportamento indicado na coluna "Padrão" e a abordagem utilizada (TD - Top Down ou BU - Bottom Up)

Tabela 5.1: Padrão encontrado - Cluster C1, K=3 | 35 amostras. Exames do grupo Memória. Total: 14 participantes

| Exame | Padrão | Relação N/T | % | Participantes (Abordagem) |
|------------|--------------------------|----------------|------|--|
| ONB | Melhorou (AV2 <= AV1) | 9/14 | 64,3 | P26(BU), P32(BU), P41(BU), P62(BU), P111(BU), P22(TD), P50(TD), P55(TD), P112(TD) |
| TWOB | Melhorou (AV2 >= AV1) | 14/14 | 100 | P3(BU), P13(BU), P26(BU), P32(BU), P41(BU), P44(BU), P62(BU), P111(BU), P22(TD), P36(TD), P50(TD), P55(TD), P95(TD), P112(TD) |
| CAMCOG_REC | Melhorou (AV2 >= AV1) | 8/14 | 57,1 | P3(BU), P13(BU), P26(BU), P62(BU), P111(BU), P22(TD), P55(TD), P95(TD) |
| HITS | Melhorou (AV2 > AV1) | 8/14 | 57,1 | P3(BU), P13(BU), P26(BU), P62(BU), P111(BU), P22(TD), P55(TD), P95(TD) |
| CR | Piorou (AV2 < AV1) | 10/14 | 71,4 | P3(BU), P13(BU), P26(BU), P32(BU), P41(BU), P44(BU), P36(TD), P50(TD), P95(TD), P112(TD) |

Tabela 5.2: Padrão encontrado - Cluster C2, K=3 | 35 amostras. Exames do grupo Memória. Total: 12 participantes

| Exame | Padrão | Relação N/T | % | Participantes (Abordagem) |
|------------|--------------------------|----------------|------|---|
| ONB | Melhorou (AV2 <= AV1) | 11/12 | 91,7 | P34(BU), P39(BU), P87(BU), P101(BU), P104(BU), P105(BU), P38(TD), P63(TD), P66(TD), P71(TD), P110(TD) |
| TWOB | Melhorou (AV2 >= AV1) | 9/12 | 75 | P34(BU), P39(BU), P87(BU), P101(BU), P104(BU), P105(BU), P63(TD), P71(TD), P66(TD) |
| CAMCOG_REC | Melhorou (AV2 >= AV1) | 11/12 | 91,7 | P39(BU), P64(BU), P87(BU), P101(BU), P104(BU), P105(BU), P38(TD), P63(TD), P71(TD), P66(TD), P110(TD) |
| HITS | Melhorou (AV2 >= AV1) | 10/12 | 83,3 | P39(BU), P64(BU), P87(BU) P101(BU), P104(BU), P105(BU) P63(TD), P71(TD), P66(TD), P110(TD) |
| CR | Melhorou (AV2 >= AV1) | 12/12 | 100 | P34(BU), P39(BU), P87(BU) P64(BU), P101(BU), P104(BU), P105(BU), P38(TD), P63(TD), P71(TD) P66(TD), P110(TD)) |

Tabela 5.3: Padrão encontrado - Cluster C3, K=3 | 35 amostras. Exames do grupo Memória. Total: 9 participantes

| Exame | Padrão | Relação N/T | % | Participantes (Abordagem) |
|------------|--------------------------|----------------|------|---|
| ONB | Piorou (AV2 > AV1) | 7/9 | 77,8 | P6(BU), P15(BU), P46(BU), P14(TD), P28(TD), P76(TD), P61(TD) |
| TWOB | Melhorou (AV2 >= AV1) | 7/9 | 77,8 | P6(BU), P15(BU), P46(BU), P108(BU), P14(TD), P24(TD), P28(TD) |
| CAMCOG_REC | Melhorou (AV2 >= AV1) | 9/9 | 100 | P6(BU), P15(BU), P46(BU), P108(BU), P14(TD), P24(TD), P28(TD), P76(TD), P61(TD) |
| HITS | Piorou (AV2 < AV1) | 8/9 | 88,9 | P6(BU), P15(BU), P46(BU), P14(TD), P24(TD), P28(TD), P76(TD), P61(TD) |
| CR | Piorou (AV2 < AV1) | 7/9 | 77,8 | P6(BU), P15(BU), P46(BU), P14(TD), P28(TD), P76(TD), P61(TD)) |

Para o cluster C1, a partir das informações da Tabela 5.1, notamos que os participantes apresentaram melhora na maioria dos exames: TWOB (todos os participantes), ONB (64,3% dos participantes), CAMCOG_REC e HITS (ambos com 57,1% dos participantes). Os participantes apresentaram declínio apenas no exame CR (71,4% dos participantes)

Tal resultado demonstra que no cluster C1, o treinamento cognitivo computadorizado se mostrou efetivo, considerando que os participantes obtiveram um melhor desempenho na maioria dos exames (4 de 5), mesmo eles sendo de naturezas e formas de pontuação diferentes, por exemplo, ONB (por tempo de resposta) e TWOB, CAMCOG_REC, HITS (por scores).

Já para o cluster C2, é possível perceber na Tabela 5.2 que os participantes do grupo apresentaram melhoria de desempenho em todos os exames: ONB (91,7%), TWOB (75%), CAMCOG_REC (91,7%), HITS (83,3%) e CR (100%). Os altos percentuais de cobertura obtidos demonstram a efetividade do treinamento para os participantes de C2.

Com os resultados obtidos no cluster C3, conforme Tabela 5.3, verificamos que os participantes agrupados nesse cluster tiveram declínio de desempenho em 3 dos 5 exames. A piora de desempenho foi observada nos exames HITS (88,9%), ONB e CR (ambos com 77,8%). Somente foram observadas melhorias nos exames TWOB (77,8%) e CAMCOG_REC (100%). Neste cluster, o treinamento cognitivo computadorizado não se mostrou efetivo após as 20 horas de treino.

Os resultados obtidos em C1, C2 e C3 evidenciam uma classificação baseada em

desempenho. No cluster C2 estão os participantes com excelente desempenho (melhoria no resultado de todos os exames), no C1 participantes com bom desempenho (melhoria em 4 de 5 exames) e no C3, participantes com baixo desempenho (declínio em 3 de 5 exames). Na tentativa de buscar características comuns os participantes que pudessem justificar a diferença de desempenho entre um participante do cluster C2 e um participante de C3, observamos o conjunto de atributos comuns como idade, anos de educação, QI, uso de medicamento, entre outros, e não foi possível estabelecer um padrão que justificasse tal diferença. Por exemplo, o participante P39 do cluster C2, que apresentou melhoria em todos os exames, possui 86 anos de idade, apenas 6 anos de escolaridade e QI 87. Já o participante P28 do cluster C3, que teve piora no desempenho em 3 dos 5 exames, é mais jovem (76 anos), tem mais escolaridade (27 anos) e maior QI (134). Cabe ressaltar que ambos os participantes não utilizam medicamento que possam influenciar nos resultados.

Tais resultados também nos permitiram notar que os participantes que apresentam um baseline bom (com melhores resultados dos exames antes do treino) tendem a se manter (caso do participante P39) ou piorar (caso do participante P28) ao longo do treinamento. Já participantes que iniciaram o treinamento com um baseline mais baixo tendem a melhorar com o treino.

Para responder a terceira questão: “*Q3: Quais são os padrões observados que demonstram a melhora de habilidades de memória, funcionalidade, atenção e velocidade de processamento de idosos, quando submetidos a jogos cognitivos computadorizados?*”, analisamos a projeção dos clusters gerados ($K=3$) para esses grupos conforme ilustra a Figura 5.5.

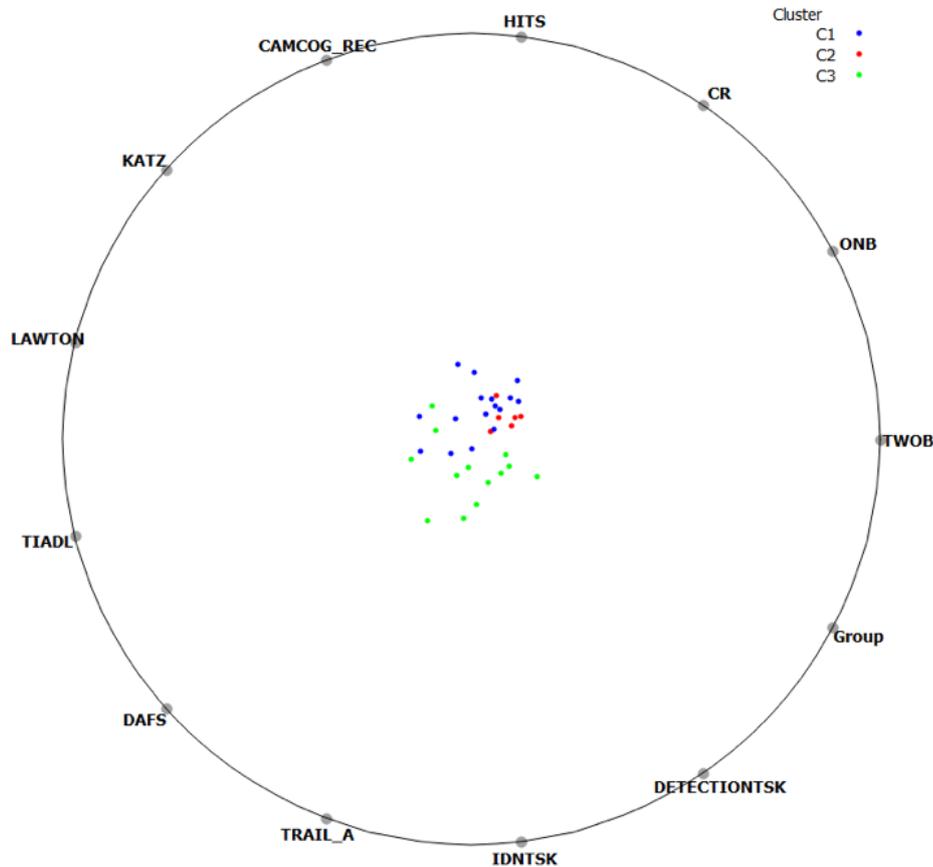


Figura 5.5: Clusters gerados para os exames dos grupos memória, funcionalidade, atenção e velocidade de processamento, considerando $K=3$

Assim como foi feito para os exames do grupo de habilidade memória (apenas), mapeamos cada participante ao seu respectivo cluster e geramos os gráficos radar de cada participante, com indicação de desempenho dos mesmos em AV1 e AV2. Posteriormente, extraímos informações a partir dos gráficos radar e registramos os resultados obtidos nos exames (melhora ou piora) em tabelas (uma para cada cluster).

As Figuras 5.6, 5.7 e 5.8 apresentam os gráficos radar gerados para os exames dos grupos memória, funcionalidade, atenção e velocidade de processamento, nos clusters C1, C2 e C3, respectivamente. E as Tabelas 5.4, 5.5 e 5.6, os resultados obtidos para C1, C2 e C3, nesta ordem.

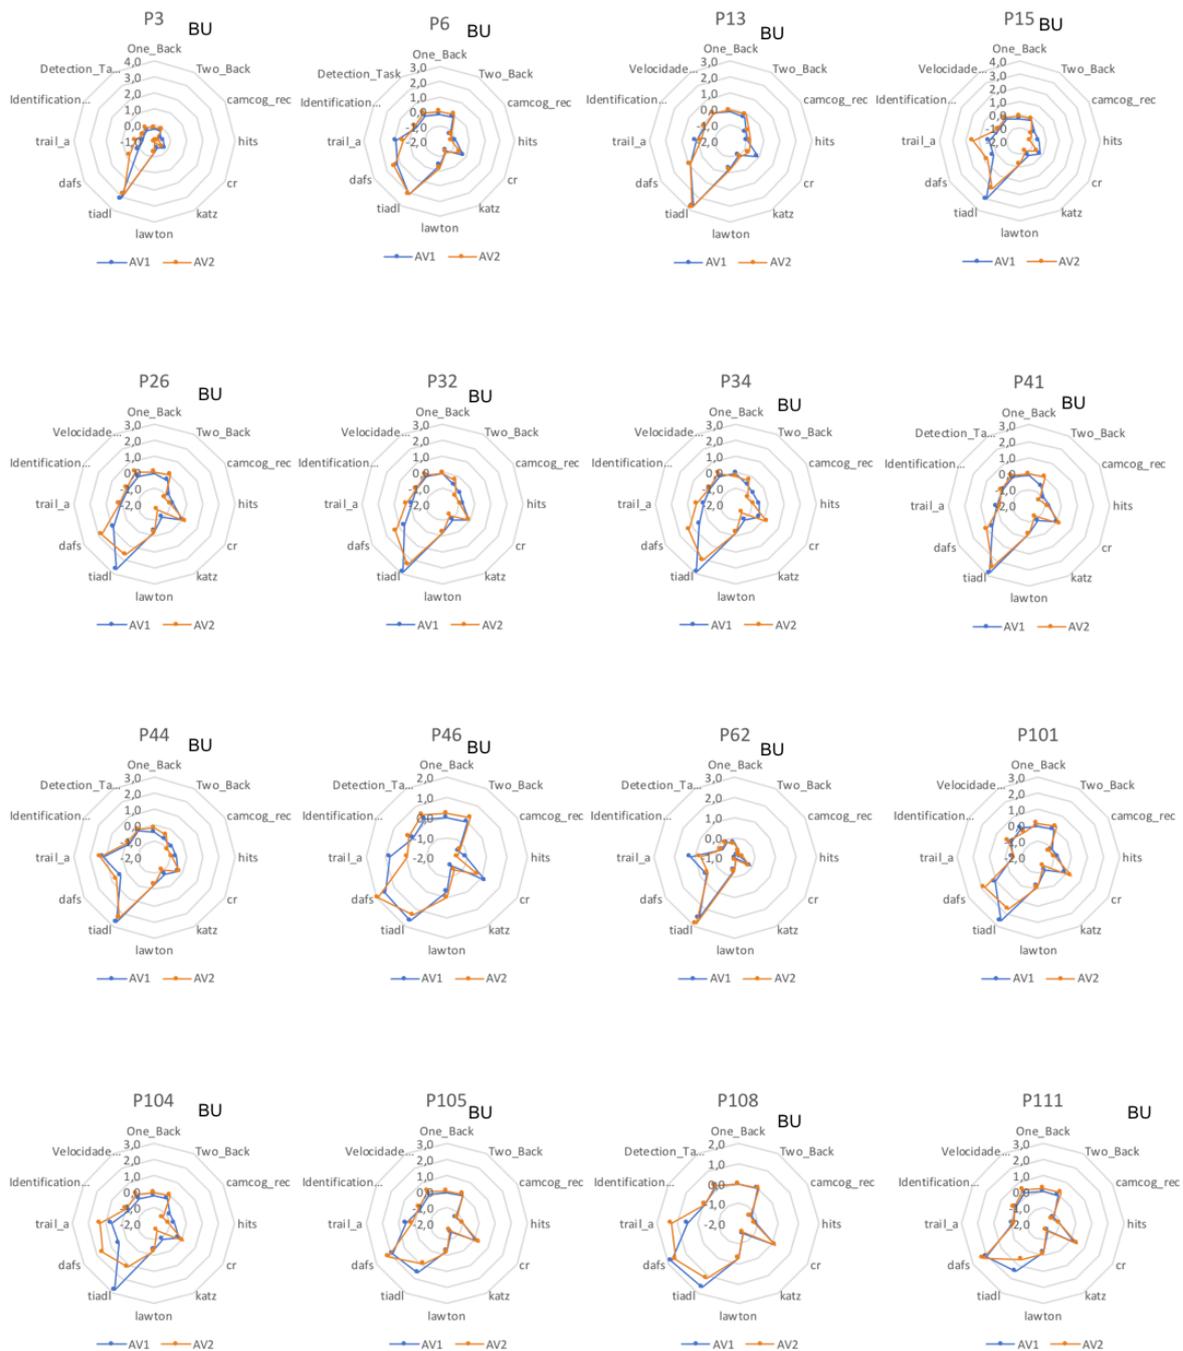


Figura 5.6: Gráficos radar de cada participante do cluster C1 e $K=3$ (com 35 amostras). Pontuações nos exames dos grupos memória, funcionalidade, atenção e velocidade de processamento. Avaliações AV1 (em azul) e AV2 (em laranja)

Observamos, por exemplo, que os participantes P26, P34 e P101 do cluster C1, mostrados na Figura 5.6 apresentam um baseline alto (antes do treino - AV1) para o exame TIADL que mede o tempo de execução de atividades específicas e que exigem um certo processamento cerebral. Nesse contexto, esses participantes possuem inicialmente um

baseline ruim e após às 20 horas de treinamento cognitivo computadorizado, eles apresentaram no exame TIADL um tempo satisfatório (menor), pontuado pela avaliação AV2, e que mostrou em uma melhor resposta cognitiva.

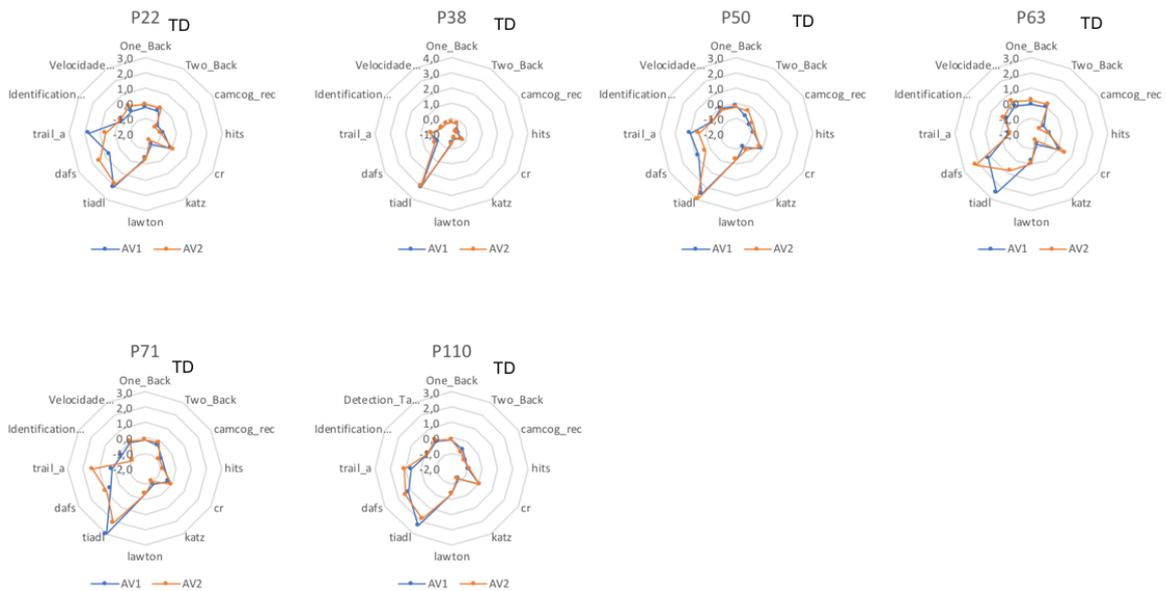


Figura 5.7: Gráficos radar de cada participante do cluster C2 e K=3 (com 35 amostras). Pontuações nos exames dos grupos memória, funcionalidade, atenção e velocidade de processamento. Avaliações AV1 (em azul) e AV2 (em laranja)

Notamos, por exemplo, que os participantes P63 e P71 pertencentes ao cluster C2, mostrados na Figura 5.7 apresentam um baseline alto (antes do treino - AV1) para o exame TIADL. Nesse contexto, esses participantes possuem inicialmente um baseline ruim e após às 20 horas de treinamento cognitivo computadorizado, eles apresentaram no exame TIADL um tempo satisfatório (menor), pontuado pela avaliação AV2, e que mostrou em uma melhor resposta cognitiva.



Figura 5.8: Gráficos radar de cada participante do cluster C3 e $K=3$ (com 35 amostras). Pontuações nos exames dos grupos memória, funcionalidade, atenção e velocidade de processamento. Avaliações AV1 (em azul) e AV2 (em laranja)

Verificamos, por exemplo, que os participantes P64, P87 e P112 pertencentes ao cluster C3, mostrados na Figura 5.8 apresentam um baseline mais baixo (antes do treino - AV1) para o exame TIADL. Nesse contexto, esses participantes possuem inicialmente um baseline bom e após às 20 horas de treinamento cognitivo computadorizado, eles apresentaram no exame TIADL um tempo insatisfatório (maior), pontuado pela avaliação AV2,

e que mostrou em uma pior resposta cognitiva.

Tabela 5.4: Padrão encontrado - Cluster C1, K=3 | 35 amostras. Exames do grupos Memória, Funcionalidade, Atenção e Velocidade de Processamento. Total: 16 participantes

| Exame | Padrão | Relação N/T | % | Participantes (Abordagem) |
|--------------|--------------------------|----------------|------|---|
| ONB | Piorou (AV2 > AV1) | 10/16 | 63 | P3(BU), P6(BU), P15(BU), P26(BU), P44(BU), P46(BU), P101(BU), P104(BU), P105(BU), P111(BU)) |
| TWOB | Melhorou (AV2 >= AV1) | 16/16 | 100 | P3(BU), P6(BU), P13(BU), P15(BU), P26(BU), P32(BU), P34(BU), P41(BU), P44(BU), P46(BU), P62(BU), P101(BU), P104(BU), P105(BU), P108(BU), P111(BU)) |
| CAMCOG_REC | Piorou (AV2 < AV1) | 12/16 | 75 | P3(BU), P15(BU), P26(BU), P32(BU), P34(BU), P41(BU), P44(BU), P101(BU), P104(BU), P105(BU), P108(BU), P111(BU)) |
| HITS | Piorou (AV2 < AV1) | 12/16 | 75 | P3(BU), P6(BU), P15(BU), P26(BU), P32(BU), P34(BU), P41(BU), P44(BU), P46(BU), P101(BU), P104(BU), P108(BU)) |
| CR | Melhorou (AV2 >= AV1) | 11/16 | 69 | P26(BU), P32(BU), P34(BU), P41(BU), P44(BU), P62(BU), P101(BU), P104(BU), P105(BU), P108(BU), P111(BU)) |
| KATZ | Piorou (AV2 < AV1) | 9/16 | 56,2 | P3(BU), P15(BU), P26(BU), P32(BU), P34(BU), P41(BU), P44(BU), P101(BU), P104(BU)) |
| LAWTON | Melhorou (AV2 >= AV1) | 16/16 | 100 | P3(BU), P6(BU), P13(BU), P15(BU), P26(BU), P32(BU), P34(BU), P41(BU), P44(BU), P46(BU), P62(BU), P101(BU), P104(BU), P105(BU), P108(BU), P111(BU)) |
| TIADL | Melhorou (AV2 <= AV1) | 15/16 | 94 | P3(BU), P6(BU), P13(BU), P15(BU), P26(BU), P32(BU), P34(BU), P41(BU), P44(BU), P46(BU), P101(BU), P104(BU), P105(BU), P108(BU), P111(BU)) |
| DAFS | Melhorou (AV2 >= AV1) | 14/16 | 88 | P3(BU), P6(BU), P13(BU), P15(BU), P26(BU), P32(BU), P34(BU), P41(BU), P44(BU), P46(BU), P101(BU), P104(BU), P105(BU), P111(BU)) |
| TRAIL_A | Melhorou (AV2 <= AV1) | 9/16 | 56,2 | P6(BU), P13(BU), P26(BU), P41(BU), P46(BU), P62(BU), P101(BU), P105(BU), P111(BU)) |
| IDNTSK | Melhorou (AV2 <= AV1) | 10/16 | 63 | P13(BU), P15(BU), P32(BU), P34(BU), P41(BU), P44(BU), P62(BU), P101(BU), P108(BU), P111(BU)) |
| DETECTIONTSK | Piorou (AV2 > AV1) | 11/16 | 69 | P3(BU), P6(BU), P15(BU), P26(BU), P34(BU), P41(BU), P44(BU), P46(BU), P104(BU), P105(BU), P111(BU)) |

Tabela 5.5: Padrão encontrado - Cluster C2, K=3 | 35 amostras. Exames do Grupos Memória, Funcionalidade, Atenção e Velocidade de Processamento. Total: 6 participantes

| Exame | Padrão | Relação N/T | % | Participantes (Abordagem) |
|--------------|--------------------------|----------------|------|---|
| ONB | Melhorou (AV2 <= AV1) | 4/6 | 67 | P38(TD), P50(TD), P71(TD), P110(TD) |
| TWOB | Melhorou (AV2 >= AV1) | 5/6 | 83,3 | P22(TD), P38(TD), P50(TD) P63(TD), P71(TD) |
| CAMCOG_REC | Melhorou (AV2 >= AV1) | 4/6 | 67 | P38(TD), P50(TD), P71(TD), P110(TD) |
| HITS | Melhorou (AV2 >= AV1) | 6/6 | 100 | P22(TD), P38(TD), P50(TD), P63(TD), P71(TD), P110(TD)) |
| CR | Melhorou (AV2 >= AV1) | 5/6 | 83,3 | P22(TD), P38(TD), P63(TD), P71(TD), P110(TD) |
| KATZ | Melhorou (AV2 >= AV1) | 4/6 | 67 | P22(TD), P38(TD), P50(TD), P110(TD) |
| LAWTON | Melhorou (AV2 >= AV1) | 6/6 | 100 | P22(TD), P38(TD), P50(TD), P63(TD), P71(TD), P110(TD) |
| TIADL | Melhorou (AV2 <= AV1) | 5/6 | 83,3 | P22(TD), P38(TD), P63(TD), P71(TD), P110(TD) |
| DAFS | Melhorou (AV2 >= AV1) | 5/6 | 83,3 | P22(TD), P38(TD), P63(TD), P71(TD), P110(TD) |
| TRAIL_A | Melhorou (AV2 <= AV1) | 4/6 | 67 | P22(TD), P38(TD), P50(TD), P63(TD) |
| IDNTSK | Melhorou (AV2 <= AV1) | 6/6 | 100 | P22(TD), P38(TD), P50(TD), P63(TD), P71(TD), P110(TD) |
| DETECTIONTSK | Melhorou (AV2 <= AV1) | 4/6 | 67 | P38(TD), P50(TD), P71(TD), P110(TD) |

Tabela 5.6: Padrão encontrado - Cluster C3, K=3 | 35 amostras. Exames do Grupos Memória, Funcionalidade, Atenção e Velocidade de Processamento. Total: 13 participantes

| Nome | Padrão | Relação N/T | % | Participantes (Abordagem) |
|--------------|--------------------------|----------------|-----|--|
| ONB | Melhorou (AV2 <= AV1) | 11/13 | 85 | P39(BU), P64(BU), P87(BU), P14(TD), P24(TD), P28(TD), P55(TD), P66(TD), P95(TD), P76(TD), P112(TD) |
| TWOB | Melhorou (AV2 >= AV1) | 11/13 | 85 | P39(BU), P87(BU), P14(TD), P24(TD), P28(TD), P36(TD), P55(TD), P61(TD), P76(TD), P95(TD), P112(TD) |
| CAMCOG_REC | Melhorou (AV2 >= AV1) | 13/13 | 100 | P39(BU), P64(BU), P87(BU), P14(TD), P24(TD), P28(TD), P36(TD), P55(TD), P61(TD), P66(TD), P76(TD), P95(TD), P112(TD) |
| HITS | Melhorou (AV2 >= AV1) | 11/13 | 85 | P39(BU), P64(BU), P87(BU), P24(TD), P36(TD), P55(TD), P61(TD), P66(TD), P76(TD), P95(TD), P112(TD) |
| CR | Melhorou (AV2 >= AV1) | 8/13 | 62 | P39(BU), P64(BU), P87(BU), P14(TD), P24(TD), P55(TD), P61(TD), P76(TD) |
| KATZ | Melhorou (AV2 >= AV1) | 13/13 | 100 | P39(BU), P64(BU), P87(BU), P14(TD), P24(TD), P28(TD), P36(TD), P55(TD), P61(TD), P66(TD), P76(TD), P95(TD), P112(TD) |
| LAWTON | Melhorou (AV2 >= AV1) | 13/13 | 100 | P39(BU), P64(BU), P87(BU), P14(TD), P24(TD), P28(TD), P36(TD), P55(TD), P61(TD), P66(TD), P76(TD), P95(TD), P112(TD) |
| TIADL | Melhorou (AV2 <= AV1) | 7/13 | 54 | P14(TD), P24(TD), P55(TD), P66(TD), P76(TD), P95(TD), P112(TD) |
| DAFS | Piorou (AV2 < AV1) | 8/13 | 62 | P64(BU), P24(TD), P36(TD), P55(TD), P66(TD), P76(TD), P95(TD), P112(TD) |
| TRAIL_A | Melhorou (AV2 <= AV1) | 9/13 | 69 | P39(BU), P87(BU), P24(TD), P28(TD), P36(TD), P55(TD), P61(TD), P95(TD), P112(TD) |
| IDNTSK | Melhorou (AV2 <= AV1) | 13/13 | 100 | P39(BU), P64(BU), P87(BU), P14(TD), P24(TD), P28(TD), P36(TD), P55(TD), P61(TD), P66(TD), P76(TD), P95(TD), P112(TD)) |
| DETECTIONTSK | Melhorou (AV2 <= AV1) | 13/13 | 100 | P39(BU), P64(BU), P87(BU), P14(TD), P24(TD), P28(TD), P36(TD), P55(TD), P61(TD), P66(TD), P76(TD), P95(TD), P112(TD)) |

A Tabela 5.4 demonstra que no cluster C1, o treinamento cognitivo computadorizado se mostrou efetivo após as 20 horas de treino, considerando que os participantes, todos do grupo BU, obtiveram melhoria de desempenho em 7 dos 12 exames (o que corresponde a 58,33% do total de exames).

Com relação cluster C2, a Tabela 5.5 revela que houve uma melhora significativa no resultado dos exames, uma vez que nenhum deles apresentou piora e o menor percentual de cobertura foi de 67% nos exames ONB, CAMCOG_REC, KATZ, TRAIL_A e DETECTIONTSK, demonstrando total efetividade do treinamento.

No cluster C3, representado na Tabela 5.6, percebemos que os participantes apresentaram declínio apenas no exame DAFS. Isso demonstra que em C3, o treinamento cognitivo computadorizado se mostrou efetivo, considerando que os participantes, sendo 3 do grupo BU e 10 do grupo TD, obtiveram um desempenho melhor em 11 de 12 exames (que corresponde a 92% dos exames).

Tal como nos clusters gerados para o grupo memória (apenas), os resultados obtidos em C1, C2 e C3 do grupo de exames em análise evidenciam uma classificação baseada em desempenho. O cluster C2 contempla participantes que obtiveram melhor resposta cognitiva, uma vez que todos os exames apresentaram status "Melhorou". O cluster C3, por sua vez, possui participantes com boa melhora cognitiva (status "Melhorou" em 92% dos exames) e o C1, a pior resposta cognitiva, uma vez que apresenta apenas 58,33% de exames com status "Melhorou".

Em busca de um padrão que justifique as diferenças de resultados entre os clusters, percebemos que o cluster C2 só tem participantes associados ao grupo TD e sendo esse cluster o que teve melhor resposta cognitiva em relação aos outros (C1 e C3), demonstra que, possivelmente, iniciando o treinamento cognitivo computadorizado pela abordagem TD, se mostre mais efetivo, já que estamos analisando as primeiras 20 horas de treino.

5.2 Mineração de dados com 51 amostras dos grupos intervenção e controle

Nesta etapa fizemos um novo procedimento de mineração de dados, desta vez incluindo 16 amostras do grupo controle. Além de fornecer um maior número de amostras para a clusterização, a inclusão dos participantes do grupo de controle permite uma melhor visualização dos resultados obtidos em cada grupo, incluindo qual apresentou melhor resposta cognitiva.

Os procedimentos realizados nesta etapa foram similares à etapa anterior, tanto para os exames pertencentes ao grupo habilidade memória, quanto aos exames pertencentes aos grupos memória, funcionalidade, atenção e velocidade de processamento.

Ainda na intenção de responder a segunda questão: “Q2: *Quais são os padrões observados, que demonstram a melhora de habilidades de memória de idosos, quando submetidos a jogos cognitivos computadorizados?*”, iniciamos pela projeção dos clusters gerados para o grupo habilidade memória. Como pode ser observado na Figura 5.9 foram gerados 4 clusters (K=4).

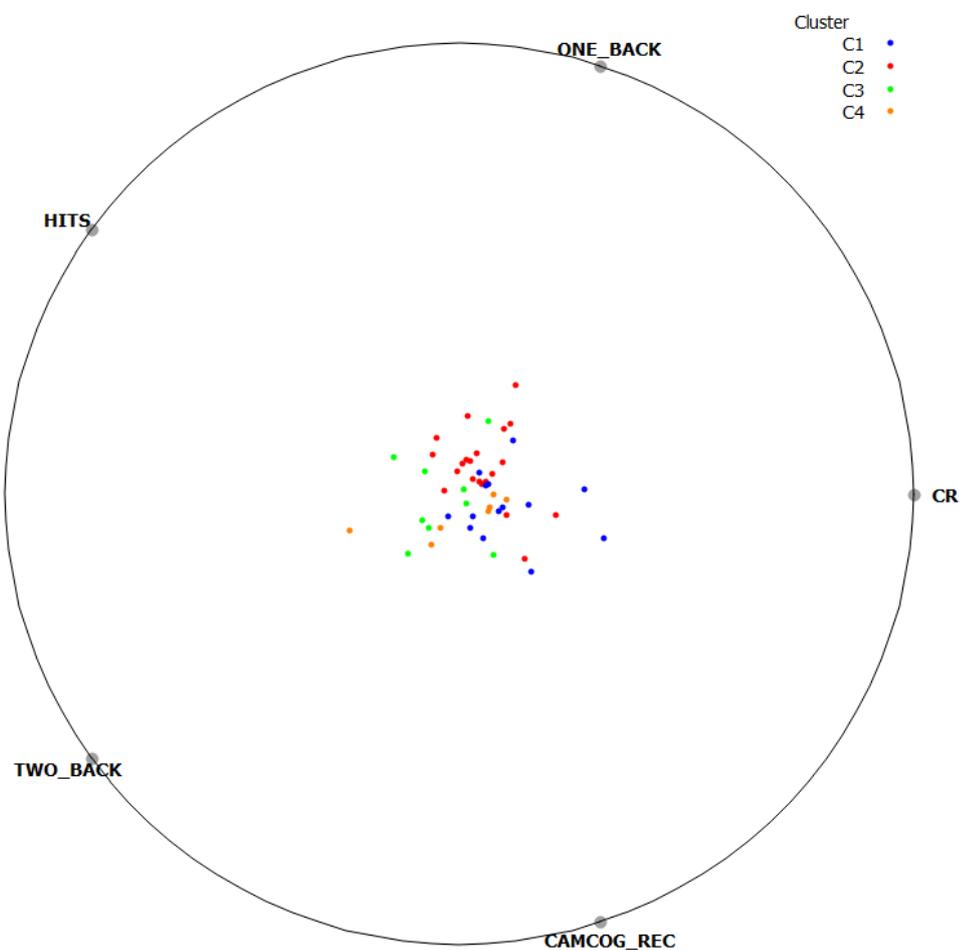


Figura 5.9: Clusters gerados para os exames do grupo memória, considerando K=4.

Após mapeamento dos participantes ao seu respectivo cluster, geramos os gráficos radar por participante e, posteriormente, construímos uma tabela com a análise das pontuações dos exames relacionados à memória.

Os gráficos radar dos clusters C1, C2, C3 e C4 estão ilustrados nas Figuras 5.10, 5.11,

5.12 e 5.13, respectivamente.

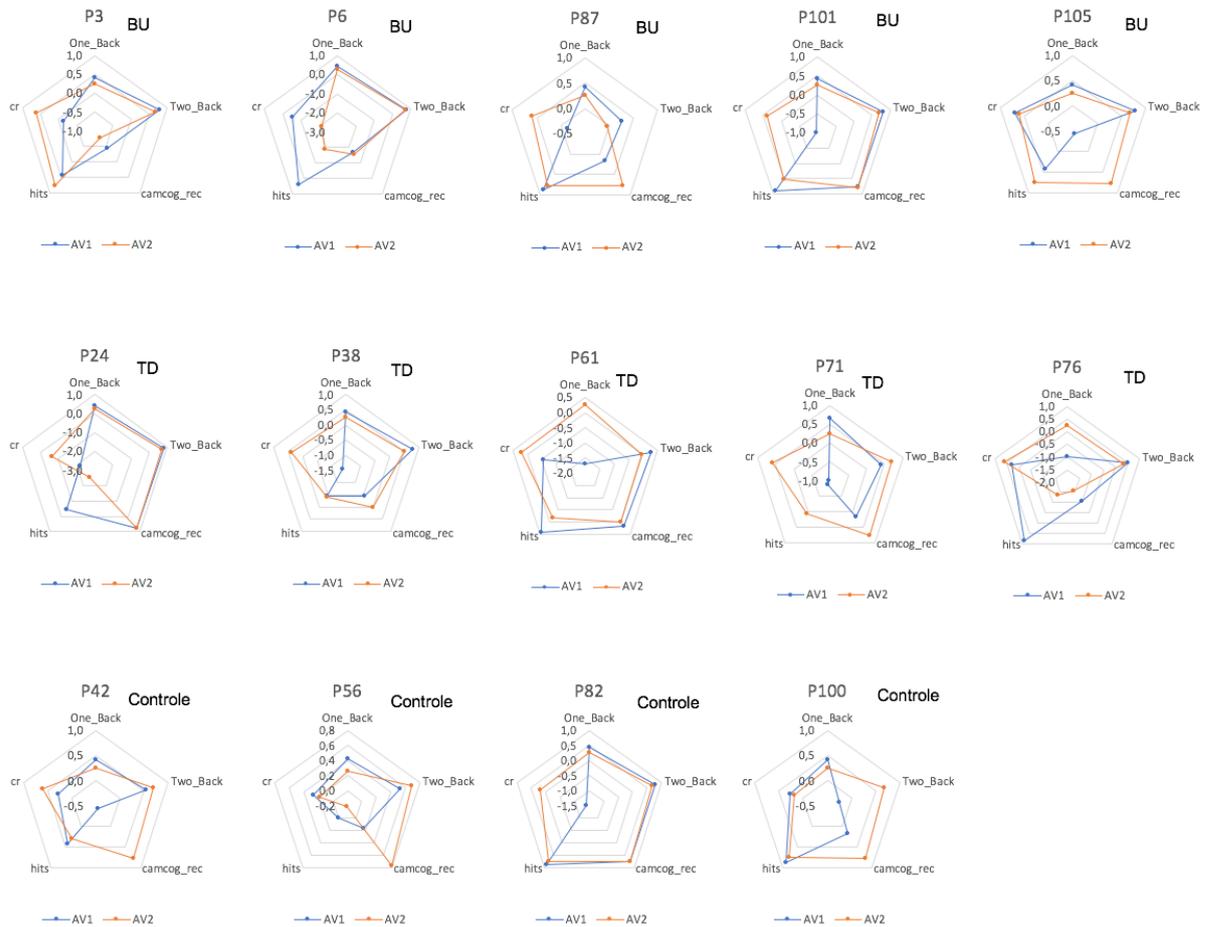


Figura 5.10: Gráficos radar de cada participante do cluster C1 e $K=4$ (com 51 amostras). Pontuações nos exames do grupo Memória. Avaliações AV1 (em azul) e AV2 (em laranja)

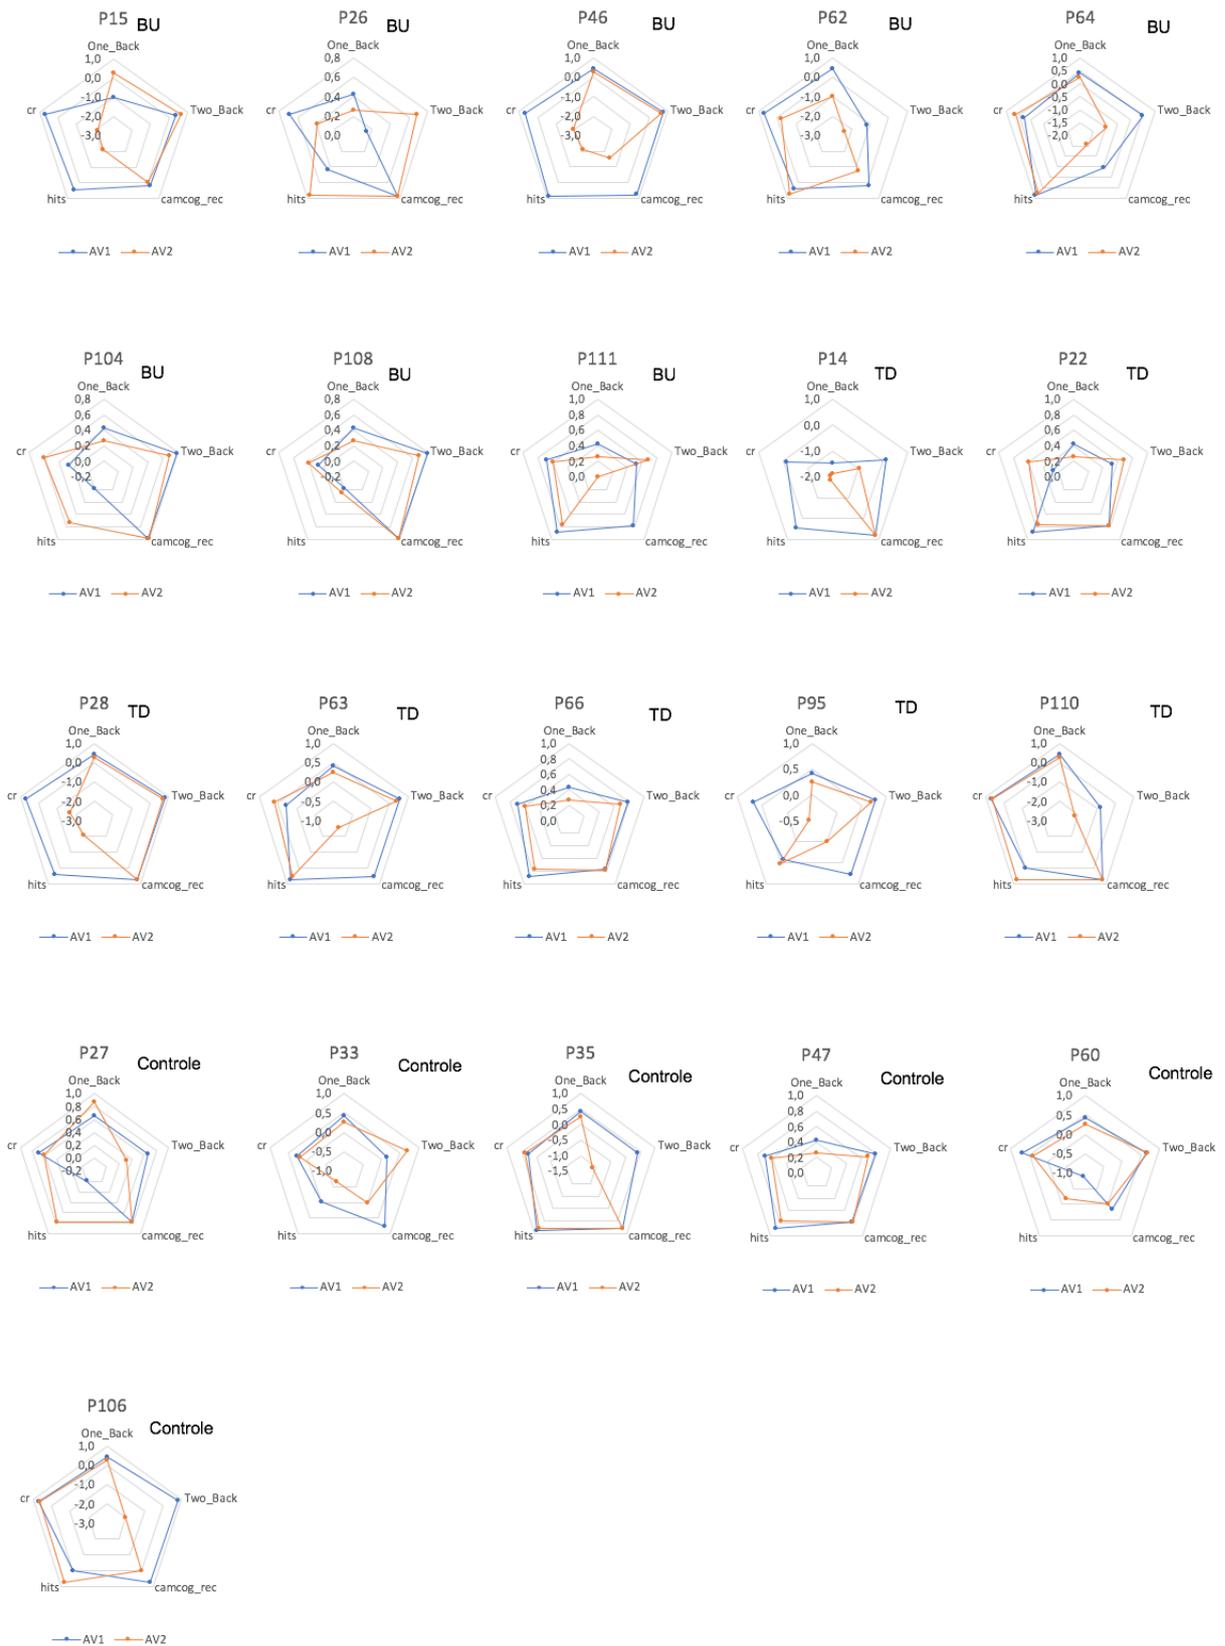


Figura 5.11: Gráficos radar de cada participantes do cluster C2 e $K=4$ (com 51 amostras). Pontuações nos exames do grupo Memória. Avaliações AV1 (em azul) e AV2 (em laranja)

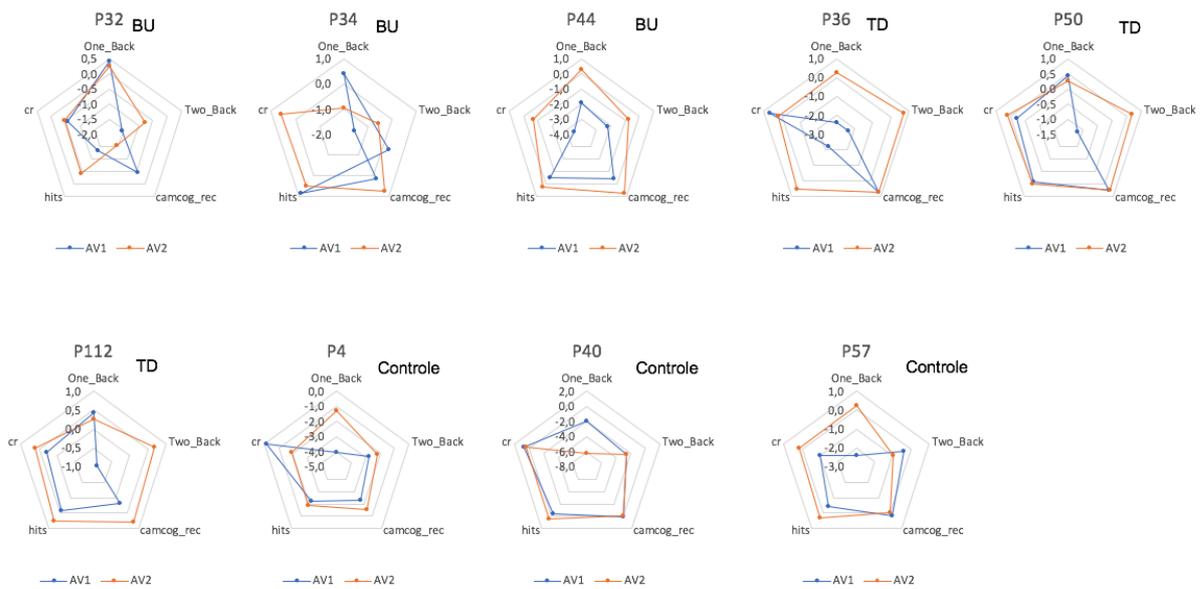


Figura 5.12: Gráficos radar de cada participante do cluster C3 e $K=4$ (com 51 amostras). Pontuações nos exames do grupo Memória. Avaliações AV1 (em azul) e AV2 (em laranja)

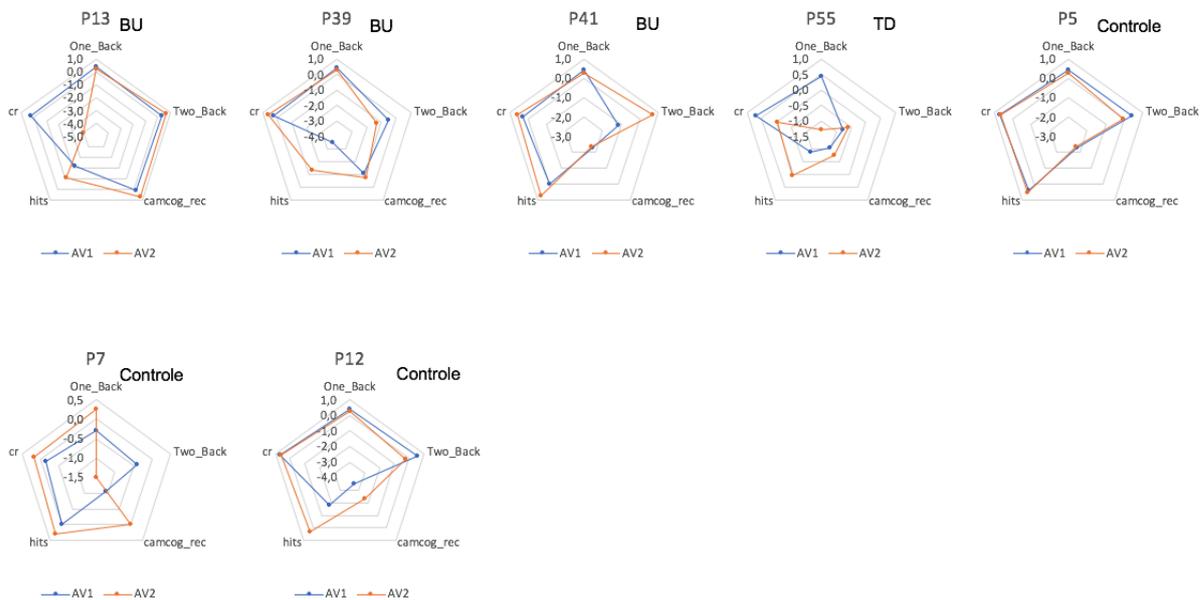


Figura 5.13: Gráficos radar de cada participante do cluster C4 e $K=4$ (com 51 amostras). Pontuações nos exames do grupo Memória. Avaliações AV1 (em azul) e AV2 (em laranja)

A construção das tabelas seguiu a mesma lógica utilizada anteriormente (mineração de dados com 35 amostras), com cinco colunas de seguinte especificação:

- **Exame**, contendo o nome do exame em questão

- **Padrão**, com o resultado do padrão obtido (representado pelas categorias melhorou ou piorou)
- **Relação N/T**, que indica a relação entre o número de participantes que apresentaram melhoria (ou não) e o total de participantes
- **%**, contendo o percentual de cobertura
- **Participantes (Abordagem)**, onde são identificados os participantes que apresentaram o comportamento indicado na coluna "Padrão" e a abordagem utilizada (TD - Top Down, BU - Bottom Up e CO - Controle)

As tabelas geradas no grupo memória para cada um dos clusters - C1, C2, C3 e C4 estão representadas nas Tabelas 5.7, 5.8, 5.9 e 5.10, respectivamente.

Tabela 5.7: Padrão encontrado - Cluster C1, K=4 | 51 amostras. Exames do grupo Memória. Total: 14 participantes

| Exame | Padrão | Relação N/T | % | Participantes (Abordagem) |
|------------|--------------------------|-------------|------|---|
| ONB | Melhorou (AV2 <= AV1) | 12/14 | 85,7 | P3 (BU), P6 (BU), P87 (BU), P101 (BU), P105 (BU), P24 (TD), P38 (TD), P71 (TD), P42 (CO), P56 (CO), P82 (CO), P100 (CO) |
| TWOB | Piorou (AV2 >= AV1) | 10/14 | 71,4 | P3 (BU), P6 (BU), P87 (BU), P101 (BU), P105 (BU), P24 (TD), P38 (TD), P61 (TD), P76 (TD), P82 (CO) |
| CAMCOG_REC | Melhorou (AV2 >= AV1) | 11/14 | 78,6 | P6 (BU), P87 (BU), P101 (BU), P105 (BU), P24 (TD), P38 (TD), P71 (TD), P42 (CO), P56 (CO), P82 (CO), P100 (CO) |
| HITS | Piorou (AV2 < AV1) | 10/14 | 71,4 | P6 (BU), P87 (BU), P101 (BU), P24 (TD), P61 (TD), P76 (TD), P42 (CO), P56 (CO), P82 (CO), P100 (CO) |
| CR | Melhorou (AV2 >= AV1) | 10/14 | 71,4 | P3 (BU), P87 (BU), P101 (BU), P24 (TD), P38 (TD), P61 (TD), P71 (TD), P76 (TD), P42 (CO), P82 (CO) |

Tabela 5.8: Padrão encontrado - Cluster C2, K=4 | 51 amostras. Exames do Grupo Memória. Total: 21 participantes

| Exame | Padrão | Relação N/T | % | Participantes (Abordagem) |
|------------|--------------------------|----------------|------|---|
| ONB | Melhorou (AV2 <= AV1) | 19/21 | 90,4 | P26 (BU), P46 (BU), P62 (BU), P64 (BU), P104 (BU), P108 (BU), P111 (BU), P14 (TD), P22 (TD), P28 (TD), P63 (TD), P66 (TD), P95 (TD), P110 (TD), P33 (CO), P35 (CO), P47 (CO), P60 (CO), P106 (CO) |
| TWOB | Piorou (AV2 < AV1) | 13/21 | 61,9 | P62 (BU), P64 (BU), P104 (BU), P108 (BU), P14 (TD), P63 (TD), P66 (TD), P95 (TD), P110 (TD), P27 (CO), P35 (CO), P47 (CO), P106 (CO) |
| CAMCOG_REC | Melhorou (AV2 >= AV1) | 11/21 | 52,4 | P26 (BU), P104 (BU), P108 (BU), P14 (TD), P22 (TD), P28 (TD), P66 (TD), P110 (TD), P27 (CO), P35 (CO), P47 (CO) |
| HITS | Piorou (AV2 < AV1) | 12/21 | 57,1 | P15 (BU), P46 (BU), P64 (BU), P111 (BU), P14 (TD), P22 (TD), P28 (TD), P63 (TD), P66 (TD), P33 (CO), P35 (CO), P47 (CO) |
| CR | Piorou (AV2 < AV1) | 15/21 | 71,4 | P15 (BU), P26 (BU), P46 (BU), P62 (BU), P111 (BU), P14 (TD), P28 (TD), P66 (TD), P95 (TD), P110 (TD), P27 (CO), P33 (CO), P47 (CO), P60 (CO), P106 (CO) |

Tabela 5.9: Padrão encontrado - Cluster C3, K=4 | 51 amostras. Exames do Grupo Memória. Total: 9 participantes

| Exame | Padrão | Relação N/T | % | Participantes (Abordagem) |
|------------|--------------------------|----------------|------|---|
| ONB | Melhorou (AV2 <= AV1) | 5/9 | 55,6 | P32 (BU), P34 (BU), P50 (TD), P112 (TD), P40 (CO) |
| TWOB | Melhorou (AV2 >= AV1) | 8/9 | 88,9 | P32 (BU), P34 (BU), P44 (BU), P36 (TD), P50 (TD), P112 (TD), P4 (CO), P40 (CO) |
| CAMCOG_REC | Melhorou (AV2 >= AV1) | 7/9 | 77,8 | P34 (BU), P44 (BU), P36 (TD), P50 (TD), P112 (TD), P4 (CO), P40 (CO) |
| HITS | Melhorou (AV2 >= AV1) | 8/9 | 88,9 | P32 (BU), P44 (BU), P36 (TD), P50 (TD), P112 (TD), P4 (CO), P40 (CO), P57 (CO) |
| CR | Melhorou (AV2 >= AV1) | 6/9 | 66,7 | P32 (BU), P34 (BU), P44 (BU), P50 (TD), P112 (TD), P57 (CO) |

Tabela 5.10: Padrão encontrado - Cluster C4, K=4 | 51 amostras. Exames do Grupo Memória. Total: 7 participantes

| Exame | Padrão | Relação N/T | % | Participantes (Abordagem) |
|------------|--------------------------|----------------|------|---|
| ONB | Melhorou (AV2 <= AV1) | 6/7 | 85,7 | P13 (BU), P39 (BU), P41 (BU), P55 (TD), P5 (CO), P12 (CO) |
| TWOB | Melhorou (AV2 >= AV1) | 4/7 | 57,1 | P39 (BU), P5 (CO), P7 (CO), P12 (CO) |
| CAMCOG_REC | Melhorou (AV2 >= AV1) | 7/7 | 100 | P13 (BU), P39 (BU), P41 (BU), P55 (TD), P5 (CO), P7 (CO), P12 (CO) |
| HITS | Melhorou (AV2 >= AV1) | 7/7 | 100 | P13 (BU), P39 (BU), P41 (BU), P55 (TD), P5 (CO), P7 (CO), P12 (CO) |
| CR | Piorou (AV2 < AV1) | 4/7 | 57,1 | P13 (BU), P55 (TD), P5 (CO), P12 (CO) |

O cluster C1, como pode ser observado na Tabela 5.7, contempla participantes de ambos os grupos (intervenção e controle) e apresentou melhora de desempenho em 3 dos 5 exames: ONB (85,7%), CAMCOG_REC (78,6%) e CR (71,4%). TWOB e HITS apresentaram declínio (ambos com 71,4%). No cluster C2, por sua vez, é possível perceber na Tabela 5.8 que os participantes do grupo apresentaram declínio de desempenho na maioria dos exames 3/5: TWOB (61,9%), HITS (57,1%) e CR (71,4%). Já o C3, de acordo com a Tabela 5.9, houve melhoria em todos os exames. E para finalizar, no cluster C4 apresentado na Tabela 5.10, 4 dos 5 exames (com exceção do CR - com 57,1% de declínio), apresentaram melhora de desempenho.

Mesmo com os resultados positivos na maioria dos clusters, o cenário apresentado se mostra de difícil análise, uma vez os clusters possuem participantes de grupos com abordagens de treinamento distintos, tornando difícil identificar algum padrão a partir do treinamento cognitivo computadorizado. Uma possível solução para esta situação, seria incluir o atributo "grupo" na clusterização. Este atributo passará a ser considerado na análise a seguir.

Em relação à terceira questão: “Q3: Quais são os padrões observados que demonstram a melhora de habilidades de memória, funcionalidade, atenção e velocidade de processamento de idosos, quando submetidos a jogos cognitivos computadorizados?”, analisamos a projeção dos clusters gerados (K=4) para esses grupos conforme ilustra a Figura 5.14.

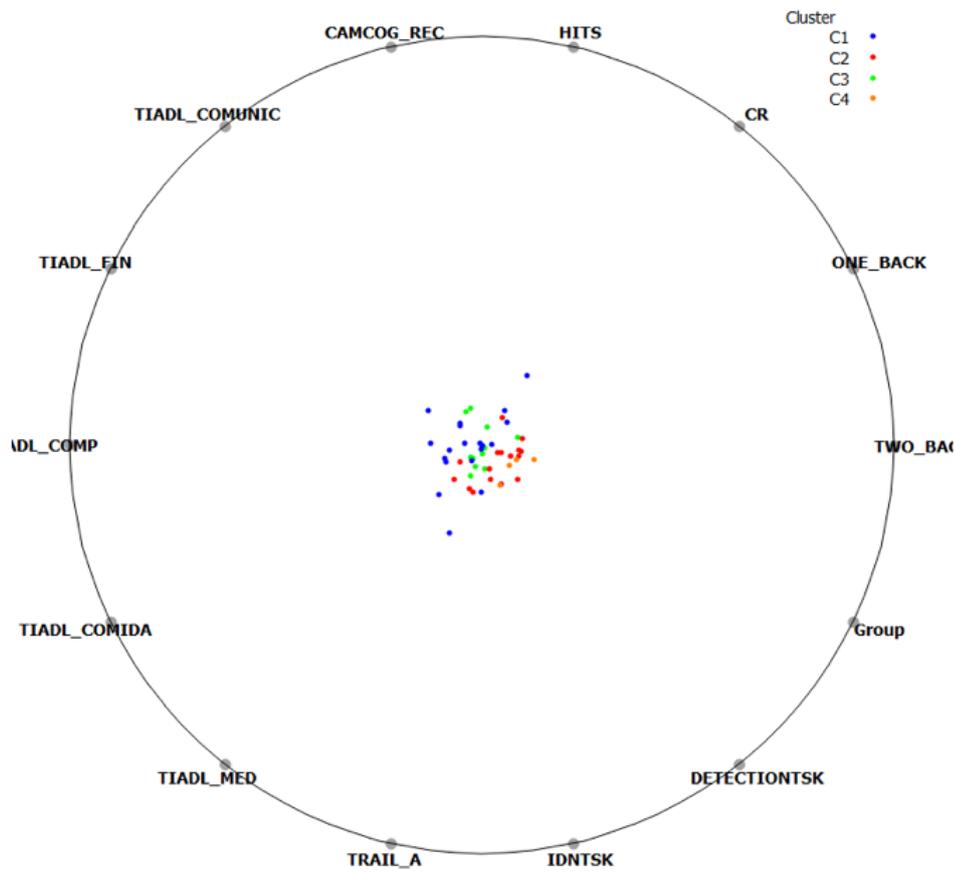


Figura 5.14: Clusters gerados para os exames dos grupos memória, funcionalidade, atenção e velocidade de processamento, considerando $K=4$

Para auxiliar na análise e visualização dos padrões realizamos o mapeamento dos participantes por cluster, geramos os gráficos radar por participante e as tabelas com os dados de cada cluster formado.

Diferentemente da clusterização feita com 51 amostras para o grupo memória (apenas), nesta clusterização além de considerar todos os exames dos grupos memória, funcionalidade, atenção e velocidade de processamento, foi incluído como atributo adicional o grupo (BU, TD ou controle).

As Figuras 5.15, 5.16, 5.17 e 5.18 ilustram os gráficos radar criados para os clusters C1, C2, C3 e C4, respectivamente. Da mesma forma, as Tabelas 5.11, 5.12, 5.13 e 5.14, apresentam os dados dos clusters C1, C2, C3 e C4, nesta ordem.

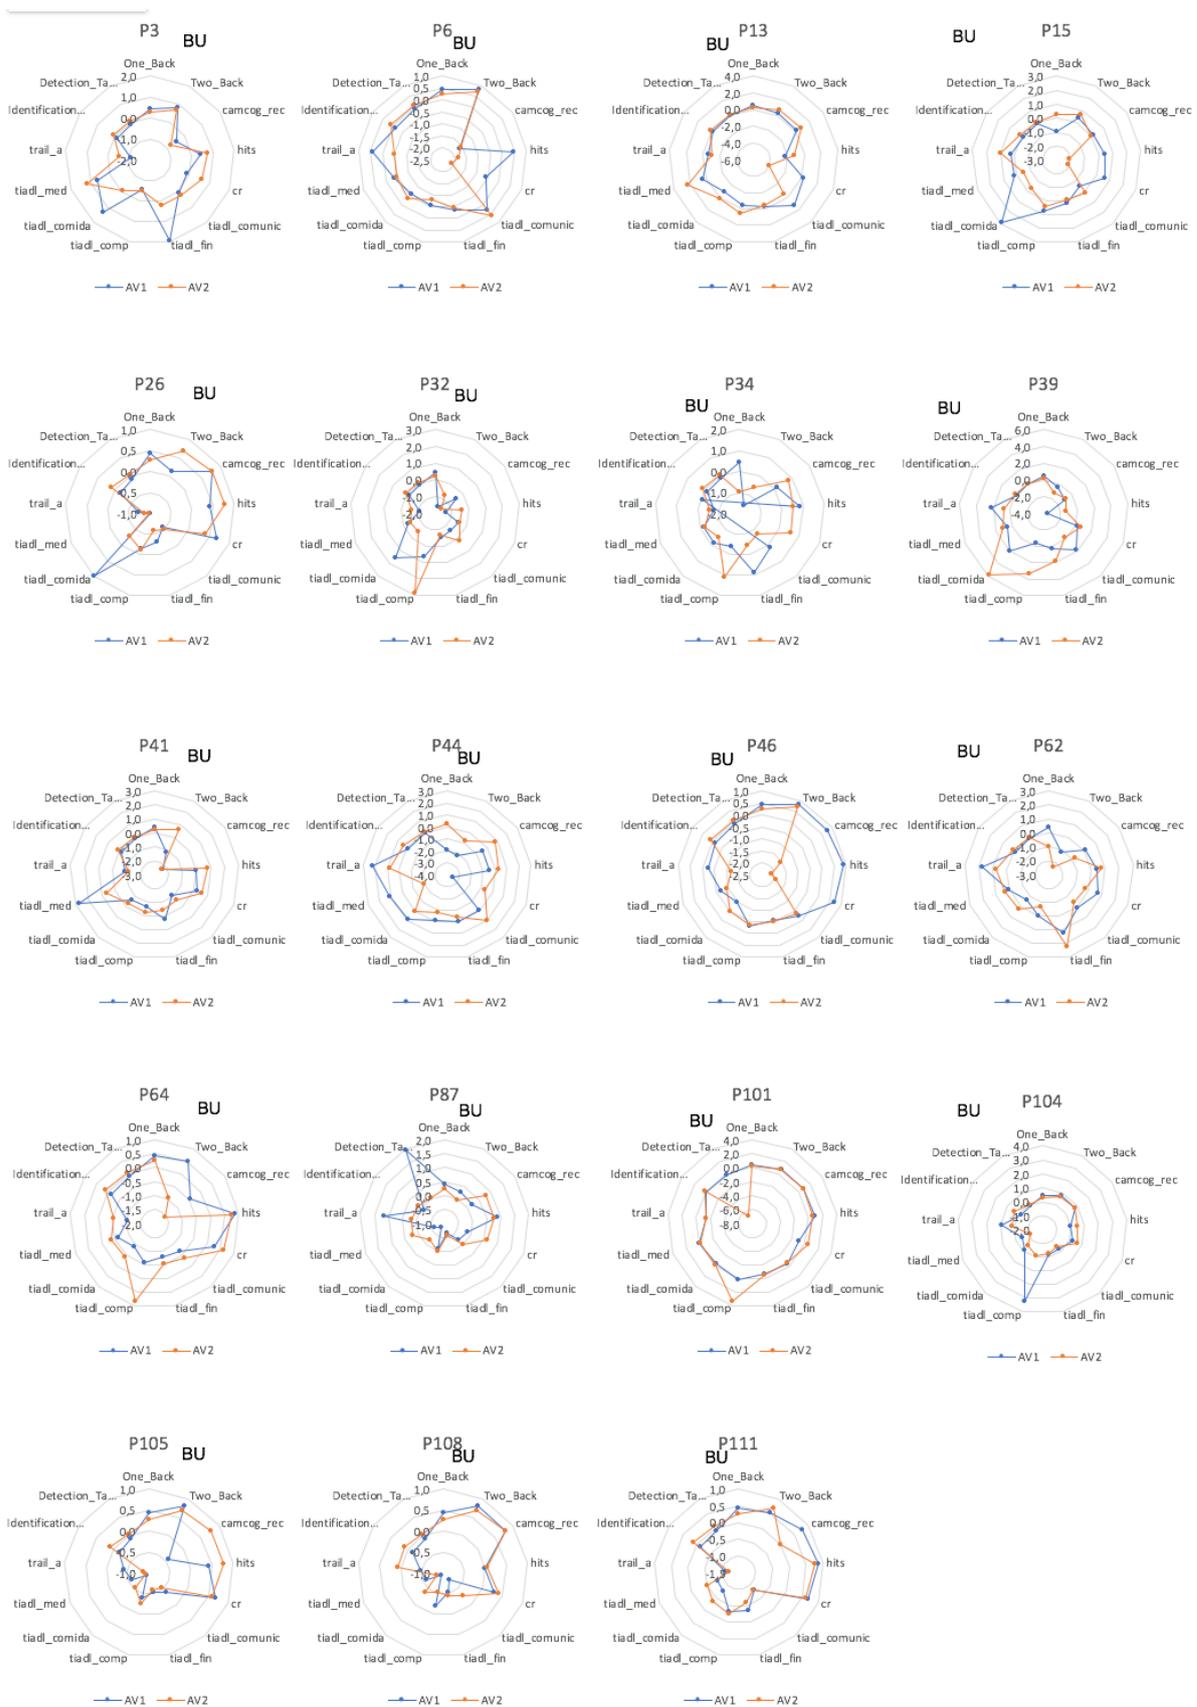


Figura 5.15: Gráficos radar de cada participantes do cluster C1 e K=4 (com 51 amostras). Pontuações nos exames dos grupos memória, funcionalidade, atenção e velocidade de processamento. Avaliações AV1 (em azul) e AV2 (em laranja)

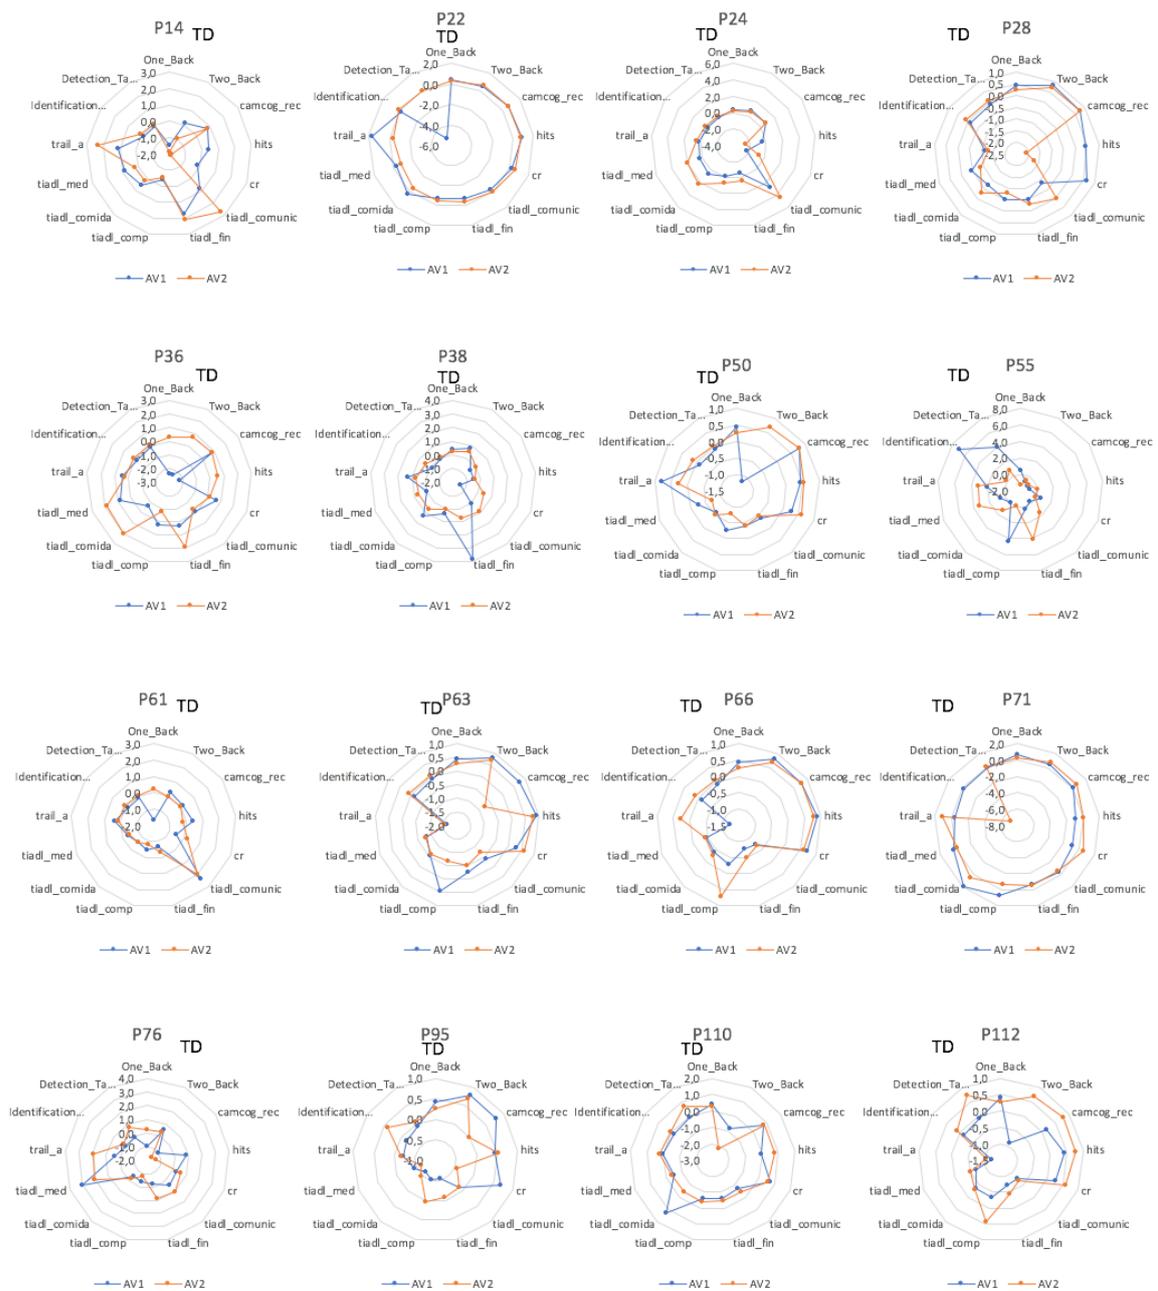


Figura 5.16: Gráficos radar de cada participante do cluster C2 e $K=4$ (com 51 amostras). Pontuações nos exames dos grupos memória, funcionalidade, atenção e velocidade de processamento. Avaliações AV1 (em azul) e AV2 (em laranja)

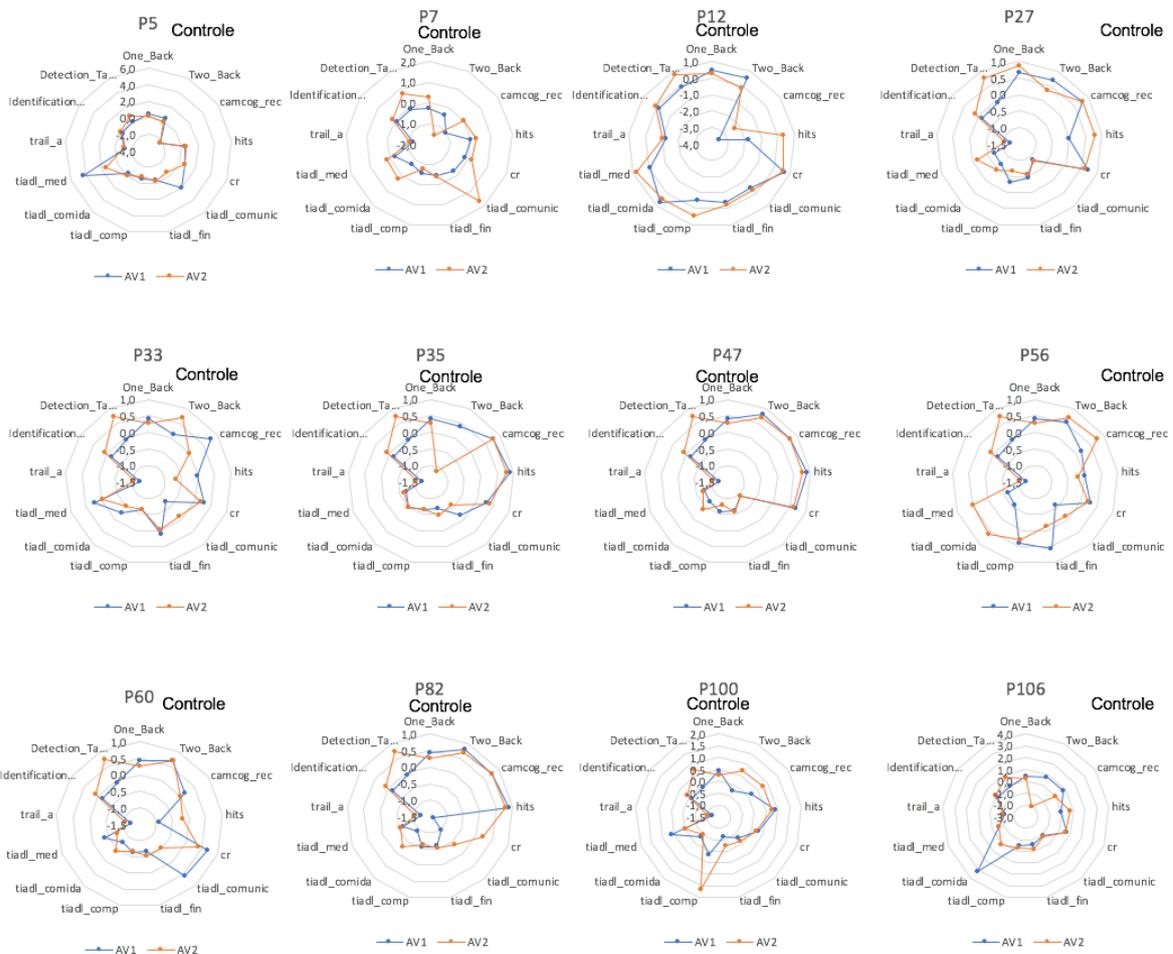


Figura 5.17: Gráficos radar de cada participantes do cluster C3 e $K=4$ (com 51 amostras). Pontuações nos exames dos grupos memória, funcionalidade, atenção e velocidade de processamento. Avaliações AV1 (em azul) e AV2 (em laranja)

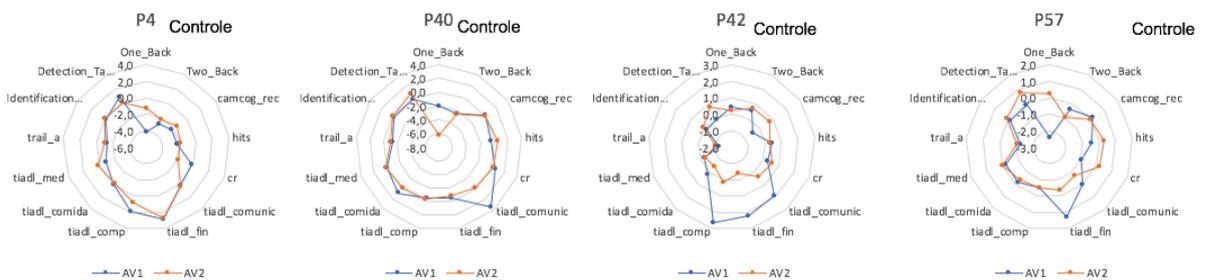


Figura 5.18: Gráficos radar de cada participantes do cluster C4 e $K=4$ (com 51 amostras). Pontuações nos exames dos grupos memória, funcionalidade, atenção e velocidade de processamento. Avaliações AV1 (em azul) e AV2 (em laranja)

Tabela 5.11: Padrão encontrado - Cluster C1, K=4 | 51 amostras. Exames do grupos Memória, Funcionalidade, Atenção e Velocidade de Processamento. Total: 19 participantes.

| Exame | Padrão | Relação N/T | % | Participantes (Abordagem) |
|---------------|--------------------------|----------------|------|---|
| ONB | Melhorou (AV2 <= AV1) | 17/19 | 89,5 | P3 (BU), P6 (BU), P13 (BU), P26 (BU), P32 (BU), P34 (BU), P39 (BU), P41 (BU), P46 (BU), P62 (BU), P64 (BU), P87 (BU), P101 (BU), P104 (BU), P105 (BU), P108 (BU), P111 (BU) |
| TWOB | Piorou (AV2 < AV1) | 11/19 | 52,6 | P3 (BU), P6 (BU), P39 (BU), P46 (BU), P62 (BU), P64 (BU), P87 (BU), P101 (BU), P104 (BU), P105 (BU), P108 (BU) |
| CAMCOG_REC | Melhorou (AV2 >= AV1) | 12/19 | 63,1 | P6 (BU), P13 (BU), P26 (BU), P34 (BU), P39 (BU), P41 (BU), P44 (BU), P87 (BU), P101 (BU), P104 (BU), P105 (BU), P108 (BU) |
| HITS | Melhorou (AV2 >= AV1) | 11/19 | 57,9 | P3 (BU), P13 (BU), P26 (BU), P32 (BU), P39 (BU), P41 (BU), P44 (BU), P62 (BU), P104 (BU), P105 (BU), P108 (BU) |
| CR | Melhorou (AV2 >= AV1) | 11/19 | 57,9 | P3 (BU), P32 (BU), P34 (BU), P39 (BU), P41 (BU), P44 (BU), P64 (BU), P87 (BU), P101 (BU), P104 (BU), P108 (BU) |
| TIADL_COMUNIC | Piorou (AV2 > AV1) | 10/19 | 52,6 | P3 (BU), P6 (BU), P15 (BU), P26 (BU), P32 (BU), P41 (BU), P44 (BU), P64 (BU), P87 (BU), P108 (BU) |
| TIADL_FIN | Melhorou (AV2 <= AV1) | 14/19 | 73,7 | P3 (BU), P6 (BU), P13 (BU), P15 (BU), P26 (BU), P32 (BU), P34 (BU), P41 (BU), P44 (BU), P46 (BU), P101 (BU), P104 (BU), P105 (BU), P111 (BU) |
| TIADL_COMP | Piorou (AV2 > AV1) | 10/19 | 52,6 | P13 (BU), P32 (BU), P34 (BU), P39 (BU), P41 (BU), P64 (BU), P87 (BU), P101 (BU), P105 (BU), P111 (BU) |
| TIADL_COMIDA | Piorou (AV2 > AV1) | 11/19 | 57,9 | P6 (BU), P13 (BU), P39 (BU), P41 (BU), P46 (BU), P62 (BU), P64 (BU), P87 (BU), P105 (BU), P108 (BU), P111 (BU) |
| TIADL_MED | Melhorou (AV2 <= AV1) | 12/19 | 63,1 | P6 (BU), P15 (BU), P26 (BU), P32 (BU), P34 (BU), P41 (BU), P44 (BU), P46 (BU), P101 (BU), P104 (BU), P105 (BU), P108 (BU) |
| TRAIL_A | Melhorou (AV2 <= AV1) | 13/19 | 68,4 | P6 (BU), P13 (BU), P26 (BU), P39 (BU), P41 (BU), P44 (BU), P46 (BU), P62 (BU), P87 (BU), P101 (BU), P104 (BU), P105 (BU), P111 (BU) |
| IDNTSK | Piorou (AV2 > AV1) | 17/19 | 89,4 | P3 (BU), P6 (BU), P15 (BU), P26 (BU), P32 (BU), P34 (BU), P39 (BU), P41 (BU), P44 (BU), P46 (BU), P62 (BU), P64 (BU), P87 (BU), P104 (BU), P105 (BU), P108 (BU), P111 (BU) |
| DETECTIONTSK | Melhorou (AV2 > AV1) | 14/19 | 73,7 | P3 (BU), P6 (BU), P15 (BU), P26 (BU), P32 (BU), P34 (BU), P39 (BU), P41 (BU), P46 (BU), P62 (BU), P64 (BU), P105 (BU), P108 (BU), P111 (BU) |

Tabela 5.12: Padrão encontrado - Cluster C2, K=4 | 51 amostras. Exames do grupos Memória, Funcionalidade, Atenção e Velocidade de Processamento. Total: 16 participantes.

| Exame | Padrão | Relação N/T | % | Participantes (Abordagem) |
|---------------|--------------------------|----------------|------|---|
| ONB | Melhorou (AV2 <= AV1) | 12/16 | 81,2 | P14 (TD), P22 (TD), P24 (TD), P28 (TD), P38 (TD), P50 (TD), P63 (TD), P71 (TD), P55 (TD), P66 (TD), P95 (TD), P110 (TD), P112 (TD) |
| TWOB | Piorou (AV2 < AV1) | 9/16 | 56,2 | P14 (TD), P28 (TD), P38 (TD), P63 (TD), P76 (TD), P61 (TD), P66 (TD), P95 (TD), P110 (TD) |
| CAMCOG_REC | Melhorou (AV2 >= AV1) | 12/16 | 75 | P14 (TD), P22 (TD), P24 (TD), P28 (TD), P38 (TD), P50 (TD), P71 (TD), P36 (TD), P55 (TD), P66 (TD), P110 (TD), P112 (TD) |
| HITS | Melhorou (AV2 >= AV1) | 9/16 | 56,2 | P22 (TD), P38 (TD), P50 (TD), P71 (TD), P36 (TD), P55 (TD), P95 (TD), P110 (TD), P112 (TD) |
| CR | Melhorou (AV2 >= AV1) | 10/16 | 62,5 | P22 (TD), P24 (TD), P38 (TD), P50 (TD), P63 (TD), P71 (TD), P76 (TD), P61 (TD), P110 (TD), P112 (TD) |
| TIADL_COMUNIC | Piorou (AV2 > AV1) | 9/16 | 56,2 | P14 (TD), P22 (TD), P24 (TD), P28 (TD), P38 (TD), P76 (TD), P55 (TD), P110 (TD), P112 (TD) |
| TIADL_FIN | Piorou (AV2 > AV1) | 12/16 | 75 | P14 (TD), P22 (TD), P24 (TD), P28 (TD), P76 (TD), P36 (TD), P55 (TD), P61 (TD), P66 (TD), P95 (TD), P110 (TD), P112 (TD) |
| TIADL_COMP | Melhorou (AV2 <= AV1) | 12/16 | 75 | P14 (TD), P22 (TD), P24 (TD), P28 (TD), P38 (TD), P50 (TD), P63 (TD), P71 (TD), P76 (TD), P36 (TD), P55 (TD), P61 (TD) |
| TIADL_COMIDA | Melhorou (AV2 <= AV1) | 10/16 | 62,5 | P14 (TD), P22 (TD), P38 (TD), P50 (TD), P63 (TD), P71 (TD), P76 (TD), P61 (TD), P110 (TD), P112 (TD) |
| TIADL_MED | Melhorou (AV2 <= AV1) | 10/16 | 62,5 | P14 (TD), P22 (TD), P28 (TD), P50 (TD), P63 (TD), P71 (TD), P76 (TD), P61 (TD), P66 (TD), P95 (TD) |
| TRAIL_A | Melhorou (AV2 <= AV1) | 9/16 | 56,2 | P22 (TD), P24 (TD), P28 (TD), P38 (TD), P50 (TD), P63 (TD), P36 (TD), P61 (TD), P95 (TD) |
| IDNTSK | Piorou (AV2 > AV1) | 12/16 | 75 | P14 (TD), P28 (TD), P38 (TD), P50 (TD), P63 (TD), P76 (TD), P36 (TD), P61 (TD), P66 (TD), P95 (TD), P110 (TD), P112 (TD) |
| DETECTIONTSK | Melhorou (AV2 <= AV1) | 9/16 | 56,2 | P14 (TD), P24 (TD), P28 (TD), P38 (TD), P63 (TD), P71 (TD), P55 (TD), P36 (TD), P61 (TD) |

Tabela 5.13: Padrão encontrado - Cluster C3, K=4 | 51 amostras. Exames do Grupos Memória, Funcionalidade, Atenção e Velocidade de Processamento. Total: 12 participantes

| Exame | Padrão | Relação N/T | % | Participantes (Abordagem) |
|---------------|--------------------------|----------------|------|---|
| ONB | Melhorou (AV2 <= AV1) | 10/12 | 83,3 | P5 (CO), P12 (CO), P33 (CO), P35 (CO), P47 (CO), P56 (CO), P60 (CO), P82 (CO), P100 (CO), P106 (CO) |
| TWOB | Piorou (AV2 < AV1) | 8/12 | 66,7 | P5 (CO), P7 (CO), P12 (CO), P27 (CO), P35 (CO), P47 (CO), P82 (CO), P106 (CO) |
| CAMCOG_REC | Melhorou (AV2 >= AV1) | 9/12 | 75 | P5 (CO), P7 (CO), P12 (CO), P27 (CO), P35 (CO), P47 (CO), P56 (CO), P82 (CO), P100 (CO) |
| HITS | Melhorou (AV2 >= AV1) | 7/12 | 58,3 | P5 (CO), P7 (CO), P12 (CO), P27 (CO), P60 (CO), P100 (CO), P106 (CO) |
| CR | Piorou (AV2 < AV1) | 7/12 | 58,3 | P12 (CO), P27 (CO), P33 (CO), P47 (CO), P56 (CO), P60 (CO), P100 (CO) |
| TIADL_COMUNIC | Piorou (AV2 > AV1) | 7/12 | 58,3 | P7 (CO), P12 (CO), P27 (CO), P33 (CO), P56 (CO), P82 (CO), P100 (CO) |
| TIADL_FIN | Piorou (AV2 > AV1) | 7/12 | 58,2 | P5 (CO), P12 (CO), P35 (CO), P60 (CO), P82 (CO), P100 (CO), P106 (CO) |
| TIADL_COMP | Melhorou (AV2 <= AV1) | 9/12 | 75 | P5 (CO), P7 (CO), P27 (CO), P33 (CO), P35 (CO), P47 (CO), P56 (CO), P60 (CO), P82 (CO) |
| TIADL_COMIDA | Piorou (AV2 > AV1) | 7/12 | 58,3 | P5 (CO), P7 (CO), P27 (CO), P47 (CO), P56 (CO), P60 (CO), P82 (CO) |
| TIADL_MED | Melhorou (AV2 <= AV1) | 7/12 | 58,3 | P5 (CO), P33 (CO), P35 (CO), P47 (CO), P60 (CO), P100 (CO), P106 (CO) |
| TRAIL_A | Melhorou (AV2 <= AV1) | 12/12 | 100 | P5 (CO), P7 (CO), P12 (CO), P27 (CO), P33 (CO), P35 (CO), P47 (CO), P56 (CO), P60 (CO), P82 (CO), P100 (CO), P106 (CO) |
| IDNTSK | Piorou (AV2 > AV1) | 12/12 | 100 | P5 (CO), P7 (CO), P12 (CO), P27 (CO), P33 (CO), P35 (CO), P47 (CO), P56 (CO), P60 (CO), P82 (CO), P100 (CO), P106 (CO) |
| DETECTIONTSK | Piorou (AV2 > AV1) | 12/12 | 100 | P5 (CO), P7 (CO), P12 (CO), P27 (CO), P33 (CO), P35 (CO), P47 (CO), P56 (CO), P60 (CO), P82 (CO), P100 (CO), P106 (CO) |

Tabela 5.14: Padrão encontrado - Cluster C4, K=4 | 51 amostras. Exames do Grupos Memória, Funcionalidade, Atenção e Velocidade de Processamento. Total: 4 participantes

| Exame | Padrão | Relação N/T | % | Participantes (Abordagem) |
|---------------|--------------------------|----------------|-----|---------------------------------------|
| ONB | Piorou (AV2 > AV1) | 2/4 | 50 | P4 (CO), P57 (CO) |
| ONB | Melhorou (AV2 <= AV1) | 2/4 | 50 | P40 (CO), P42 (CO) |
| TWOB | Melhorou (AV2 >= AV1) | 3/4 | 75 | P4 (CO), P40 (CO), P42 (CO) |
| CAMCOG_REC | Melhorou (AV2 >= AV1) | 3/4 | 75 | P4 (CO), P40 (CO), P42 (CO) |
| HITS | Melhorou (AV2 >= AV1) | 3/4 | 75 | P4 (CO), P40 (CO), P57 (CO) |
| CR | Piorou (AV2 < AV1) | 3/4 | 75 | P40 (CO), P42 (CO), P57 (CO) |
| TIADL_COMUNIC | Melhorou (AV2 <= AV1) | 3/4 | 75 | P40 (CO), P42 (CO), P57 (CO) |
| TIADL_FIN | Melhorou (AV2 <= AV1) | 4/4 | 100 | P4 (CO), P40 (CO), P42 (CO), P57 (CO) |
| TIADL_COMP | Melhorou (AV2 <= AV1) | 3/4 | 75 | (P4 (CO), P42 (CO), P57 (CO)) |
| TIADL_COMIDA | Melhorou (AV2 <= AV1) | 4/4 | 100 | P4 (CO), P40 (CO), P42 (CO), P57 (CO) |
| TIADL_MED | Piorou (AV2 > AV1) | 3/4 | 75 | P4 (CO), P40 (CO), P57 (CO) |
| TRAIL_A | Melhorou (AV2 <= AV1) | 4/4 | 100 | P4 (CO), P40 (CO), P42 (CO), P57 (CO) |
| IDNTSK | Piorou (AV2 > AV1) | 4/4 | 100 | P4 (CO), P40 (CO), P42 (CO), P57 (CO) |
| DETECTIONTSK | Piorou (AV2 <= AV1) | 3/4 | 75 | P40 (CO), P42 (CO), P57 (CO) |

A Tabela 5.11 demonstra que no cluster C1, o treinamento cognitivo computadorizado se mostrou efetivo, considerando que os participantes, todos do grupo intervenção (BU), obtiveram melhoria de desempenho em 8 dos 13 exames (o que corresponde a 61,54% do total de exames).

Com relação ao cluster C2, a Tabela 5.12 mostra que houve melhora em 9 dos 13 exames (corresponde a 69,23% do total), considerando participantes do grupo de intervenção (TD).

Como nos clusters C1 e C2 os participantes foram divididos em grupos BU e TD, respectivamente, foi realizado uma análise de dados com o intuito de verificar os dados demográficos desses participantes, conforme tabela 5.15. Nessa tabela, consideramos os

indivíduos que tiveram status distintos nos exames nesses clusters. Por exemplo, no cluster C1 os participantes apresentaram status de "Melhora" em determinados exames e o cluster C2 os participantes apresentaram status de "Piora" nos mesmos exames que C1 ou vice-versa.

Tabela 5.15: Dados demográficos dos participantes dos clusters C1 e C2 que apresentaram status distintos entre os exames

| | Bottom up (BU) <i>MD ± DP</i> | Top Down (TD) <i>MD ± DP</i> |
|---|---|--|
| Age (Idade) | 71,95 ± 7,07 | 72,06 ± 5,17 |
| Years Education (Anos Escolaridade) | 15,79 ± 5,68 | 15,25 ± 6,69 |
| IQ (QI) | 110,32 ± 13,91 | 111,94 ± 15,72 |

Observando a Tabela 5.15, percebemos que não houve uma diferença significativa entre os valores médios dos dados demográficos dos participantes dos clusters C1 e C2. Com isso, foi construído os gráficos radar, apresentados na Figura 5.19, no intuito de verificar o desempenho dos participantes ao longo do tempo entre os grupos BU e TD com base no baseline e no pós treino de 20h.

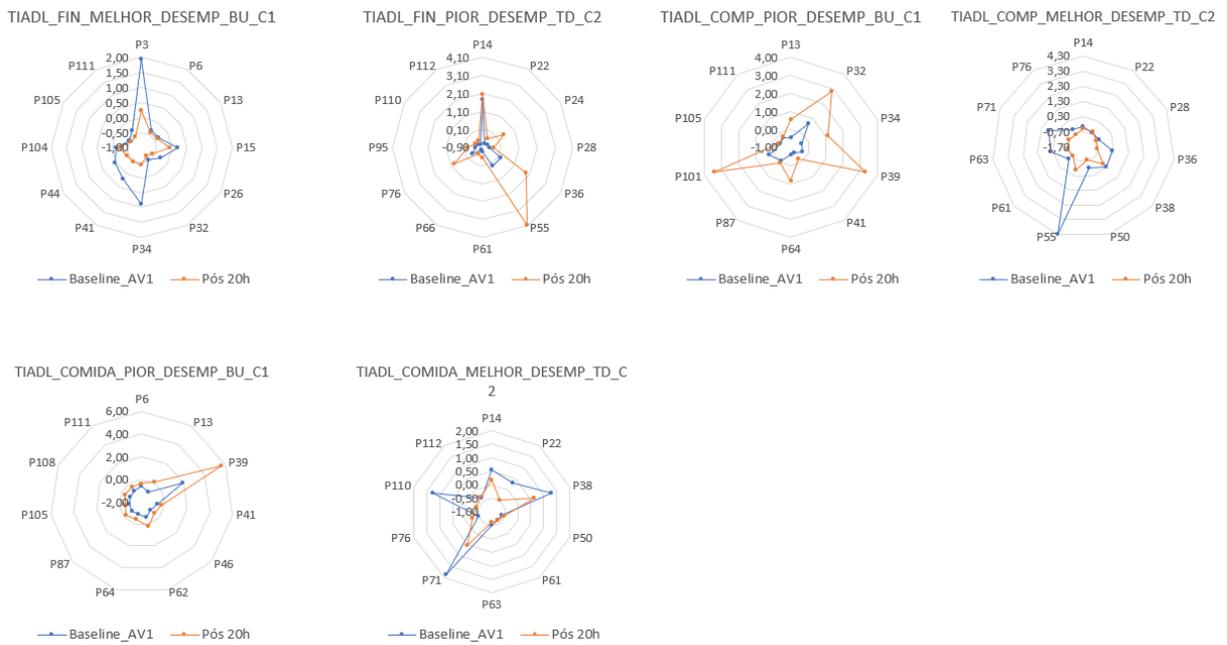


Figura 5.19: Gráficos radar dos participantes dos clusters C1 e C2 que possuem resultados divergentes nos exames TIADL_FIN, TIADL_COMP e TIADL_COMIDA

Podemos perceber nos gráficos radar (Figura 5.19) que os exames que apresentaram diferença em seus status ("Melhora" ou "Piora"), nos clusters C1 e C2, são aqueles medidos por tempo. Logo, notamos que se o status for "Pior", então $AV2 > AV1$ e se for "Melhor", $AV2 \leq AV1$. Nesse contexto, observamos que os participantes do grupo BU avaliados no exame TIADL_FIN (finanças) no pós treino de 20h em relação aos seus baselines, tiveram uma melhor resposta cognitiva em comparação com os participantes do grupo TD do mesmo exame. Além disso, verificamos que os participantes do grupo TD tiveram uma melhor resposta cognitiva nos exames TIADL_COMP (compras) e TIADL_COMIDA, também medidos por tempo em segundos em relação aos participantes do grupo BU.

No exame TIADL_FIN, podemos notar que o participante "P3" do grupo BU iniciou com um baseline ruim (maior) em relação aos outros indivíduos e ao longo do tempo no treinamento desenvolveu uma melhor resposta cognitiva ($AV2 \leq AV1$). Ao contrário do que é verificado no participante "P55 (TD)" que inicialmente possui um baseline bom (menor) e que ao longo do tempo no treino cognitivo, apresentou um tempo de resposta cerebral ruim ($AV2 > AV1$). Ainda analisando esses dois participantes ("P3 (BU)" e "P55 (TD)"), percebemos em seus dados demográficos que o participante "P3 (BU)" apresenta a idade = 71 anos, educação em anos = 16 e QI = 108. Ao contrário do participante

"P55 (TD)" que apresenta a idade = 68 anos, educação em anos = 9 e QI = 95. O que mostra que o participante "P3 (BU)" iniciou com um baseline ruim e ao longo do tempo conseguiu ser efetivo, o que não ocorreu com o participante "P55 (TD)", provavelmente, devido a natureza do exame TIADL_FIN que exige uma certa habilidade em manipular as finanças (dar troco). Talvez para esse participante seja necessário um treinamento cognitivo direcionado a finanças.

No exame TIADL_COMP (compras), podemos verificar que o participante "P55 (TD)" do grupo TD iniciou um baseline ruim (maior) em relação aos outros indivíduos e ao longo do tempo no treino desenvolveu uma melhor resposta cognitiva ($AV2 \leq AV1$). Ao contrário, do que é verificado no participante "P39 (BU)" que inicialmente possui um baseline bom (menor) e que ao longo do tempo no treino cerebral, apresentou um tempo de resposta cognitivo ruim ($AV2 > AV1$). Ainda analisando esses dois participantes ("P55 (TD)" e "P39 (BU)"), notamos que os seus dados demográficos mostram que o participante "P55 (TD)" apresenta a idade = 68 anos, educação em anos = 9 e QI = 95. Ao contrário do participante "P39 (BU)" que apresenta a idade = 86 anos, educação em anos = 6 e QI = 87. O que mostra que o participante "P55 (TD)" iniciou com um baseline ruim e ao longo do tempo conseguiu ser efetivo, o que não ocorreu com o participante "P39 (BU)", provavelmente, devido a natureza do exame TIADL_COMP que exige uma certa habilidade em encontrar dois itens específicos entre vários produtos. Talvez para esse participante seja necessário um treinamento cognitivo direcionado a compras ou possivelmente esse participante não apresentou um bom engajamento ao longo do treinamento cognitivo computadorizado.

No exame TIADL_COMIDA, podemos verificar que o participante "P71 (TD)" do grupo TD iniciou um baseline ruim (maior) em relação aos outros indivíduos e ao longo do tempo no treinamento desenvolveu uma melhor resposta cognitiva ($AV2 \leq AV1$). Ao contrário do que foi verificado no participante "P39 (BU)" que inicialmente possui um baseline bom (menor) e que ao longo do tempo no treino cognitivo, apresentou um tempo de resposta cerebral ruim ($AV2 > AV1$). Ainda analisando esses dois participantes ("P71 (TD)" e "P39 (BU)"), notamos que o participante "P71 (TD)" apresenta a idade = 81 anos, educação em anos = 18 e QI = 108. Ao contrário do participante "P39 (BU)" que apresenta a idade = 86 anos, educação em anos = 6 e QI = 87. O que mostra que o participante "P71 (TD)" iniciou com um baseline ruim e ao longo do tempo conseguiu ser efetivo, o que não ocorreu com o participante "P39 (BU)", provavelmente, devido a natureza do exame TIADL_COMIDA que exige uma certa habilidade em buscar os ingredientes em uma lata e ler os três primeiros em voz alta. Talvez para esse participante

seja necessário um treinamento cognitivo direcionado a estimular essa habilidade cognitiva ou o mesmo não apresentou um bom engajamento ao longo do treinamento cognitivo computadorizado.

O cluster C3 é representado na Tabela 5.13 por participantes do grupo de controle. Neste cluster a maioria dos exames 7/13 (53,85%) apresentou declínio nos resultados, o que pode indicar que mesmo apresentando melhora em resultados de alguns exames, os jogos comerciais não são tão efetivos quanto os jogos cognitivos computadorizados, utilizados pelos participantes do grupo intervenção, agrupados nos clusters C1 e C2.

O cluster C4, apresentado na Tabela 5.14, também foi caracterizado por participantes do grupo controle. A diferença do cluster C4 para o C3 é que, no caso do C4, a maioria dos exames 8/13 (61,54% do total) apresentaram melhores resultados em relação ao grupo intervenção. Apesar de ser um número pequeno de participantes (4), o resultado obtido pode indicar que para a maioria dos exames analisados (exceções: CR - do grupo memória, TIADL_MED - do grupo funcionalidade, IDNTSK - do grupo atenção e DETECTIONTSK - grupo velocidade de processamento), os jogos comerciais contribuem para alguma melhoria cognitiva.

Analisando o resultado de alguns exames que possuem certa complexidade, tanto os que requerem tempo de resposta (TIADL_Comunic, TIADL_Fin, TIADL_Comp, TIADL_Comida, TIADL_Med e DETECTIONTSK), quanto os de pontuação (CR) nos clusters C1, C2 e C3 - que possuem quantitativo mais significativo de participantes, percebemos que os participantes do grupo TD apresentaram melhor resposta cognitiva, seguido pelo BU. Os participantes do grupo controle apresentaram declínio no desempenho de 5 dos 7 exames considerados.

5.3 Discussão dos resultados com a literatura existente

Muitos trabalhos da área da saúde realizam análises de dados para medir desempenho cognitivo entre grupos de participantes utilizando instrumentos estatísticos que lidam com um número significativo de amostras, como o Teste T Student e ANOVA, por exemplo. O trabalho de Chi, Agama e Prodanoff (2017), da área de Ciência da Computação, seguiu essa linha, ao propor o jogo *Smart Thinker* e analisar sua efetividade com participantes idosos. Os autores selecionaram 59 idosos e aplicaram o exame Mini Mental State Examination nesses indivíduos para verificar a melhora cognitiva, fazendo análise estatística dos resultados com Levene's e Teste T Student. Whitlock, McLaughlin e Allaire (2012),

por sua vez, utilizou análise estatística com ANOVA para verificar eficácia do jogo *War of Warcraft* na melhoria das habilidades cognitivas de participantes idosos.

Embora nossa análise esteja baseada em um misto de técnicas de mineração de dados e visualização ao invés de análise puramente estatística como aquela proposta por Whitlock, McLaughlin e Allaire (2012), nossos resultados foram convergentes com os desses autores em alguns aspectos. Um deles está relacionado a ausência de relacionamento entre idade e mudança cognitiva, ou seja, a idade dos participantes não mostrou influenciar na melhora/piora da resposta cognitiva. Um outro resultado similar ao de Whitlock, McLaughlin e Allaire (2012) é a constatação de que idosos com desempenho ruim inicialmente podem se beneficiar mais do treino. Em nossos resultados, idosos com baseline ruim (baixa pontuação exames baseados em ponto ou alta pontuação em exames mensurados por tempo) tenderam a melhorar a resposta cognitiva, já idosos com bom baseline tenderam a estagnar ou piorar a resposta. No último caso (de piora), provavelmente relacionado ao não engajamento deste participante nas atividades, o que precisa ser mais explorado.

Soluções que integram mineração de dados no contexto de treinamento cognitivo computadorizado com idosos, até onde é de nosso conhecimento, são ainda pouco exploradas na literatura de Ciência da Computação. A pesquisa de Frantzidis et al. (2014), da área de Saúde, abordou o treinamento cognitivo computadorizado para facilitar a interação harmônica de regiões de cérebro, com intuito de melhorar o desempenho cognitivo de idosos. Cabe recordar que a hipótese dos autores foi que um programa de intervenção baseado em neuroplasticidade deveria induzir o aumento da sincronização entre regiões distantes do cérebro. Tal hipótese foi verificada a partir da análise de exames de eletroencefalograma dos participantes idosos em treino, com a utilização de um classificador baseado na distância de Mahalanobis (Md). Como dito anteriormente, os resultados da pesquisa mostraram que o treinamento contribuiu para melhora da estrutura neurofisiológica do cérebro. Apesar de Frantzidis et al. (2014) terem utilizado um conjunto de ferramentas próprias para treinamento (tanto cognitivo, quanto físico), algumas dessas ferramentas foram baseadas em soluções da Posit Science - fabricante do BrainHQ, utilizado na presente pesquisa. Além disso, o processo de treino proposto pelos autores é similar ao realizado no Projeto Academia do Cérebro, estudo de caso abordado em nossa pesquisa. Nesse contexto, o trabalho de Frantzidis et al. (2014) juntamente com o nosso estudo apontam para o fato de que um melhor entendimento das variáveis que influenciam no contexto do treinamento cognitivo computadorizado se faz ainda necessário.

Os resultados obtidos nessa pesquisa, diferenciam-se dos trabalhos mencionados tanto pelo contexto sociocultural (idosos brasileiros que interagem com um conjunto de jogos cognitivos computadorizados) e conjunto de técnicas aplicadas (mineração de dados com algoritmo K-means e visualização com gráficos radar) quanto pela divisão de abordagem dos jogos em Top Down (TD) e Botton Up (BU) aplicada durante o treinamento. Resultados mostraram a possibilidade de se propor treinamentos personalizados de acordo com o resultado dos exames de baseline obtidos. A análise realizada considerando o grupo como atributo adicional para a extração de padrão serviu principalmente para mostrar que existe uma diferença nos resultados obtidos para os exames de memória, funcionalidade, atenção e velocidade de processamento entre os participantes que seguiram a abordagem TD, os que seguiram BU e os participantes do grupo de Controle (CO). Esta diferença não está relacionada a idade e nem ao QI mas sim os seu estagio inicial. Ou seja, participantes avaliados com um baseline inicial baixo tem mais chances de ganhos efetivos com o treinamento e participantes que apresentam um baseline mais alto possuem menos chances de desenvolver tais habilidades (memória, funcionalidade, atenção e velocidade de processamento) ao longo do treinamento.

Cabe destacar que a revisão de literatura feita por Jothi, Rashid e Husain (2015) resultou em poucos artigos (3, no universo de 50) que utilizassem funções de aprendizado não supervisionado na descoberta de padrões (modelos descritivos) aplicados à área da saúde. A técnica de clusterização também foi muito pouco explorada de acordo com os autores: apenas 2 dos 50 trabalhos capturados na revisão. A presente dissertação contribui para o corpo de conhecimento no contexto da mineração de dados aplicada à saúde, uma vez que utiliza um modelo descritivo (com clusterização) para apoiar a identificação de padrões de interação no treinamento cognitivo de idosos.

Capítulo 6

Conclusão e Trabalhos Futuros

Nesta pesquisa, introduzimos um modelo de dados e um banco de dados para armazenamento de informações sobre o treinamento cognitivo computadorizado. A partir das informações obtidas desse modelo estruturado, propusemos uma análise de dados com mineração de dados para extração de conhecimentos sobre os dados de treinamento.

Essas análises podem auxiliar os pesquisadores da saúde a extrair informações úteis e, em seguida, obterem respostas mais precisas que os ajudem a descobrir padrões que melhor expliquem os resultados obtidos com o método de treinamento cognitivo computadorizado aplicado aos participantes idosos.

Utilizamos como estudo de caso 18 exames de desempenho do idoso, antes e após o treinamento cognitivo, aplicando medidas de análise de dados para o cálculo da probabilidade do tamanho do efeito, com base nas pontuações extraídas para aquele conjunto de exames, a fim de analisar o desempenho dos participantes, como parte do processo de mineração de dados para tomada de decisão.

Posteriormente, utilizamos técnicas de mineração de dados para habilidade de memória e habilidades de memória, funcionalidade, atenção e velocidade de processamento, com o objetivo de analisar o desempenho dos participantes considerando os grupos BU e TD. Com isso foi possível extrair padrões que apontaram pontos fortes e fracos do treinamento os quais podem ser explorados em futuros treinamentos.

Os resultados obtidos com a aplicação das técnicas de mineração de dados e visualização de scores de exames dos grupos de habilidade memória e dos grupos habilidades memória, funcionalidade, atenção e velocidade de processamento, demonstraram que existem padrões de interação diferenciados entre seus participantes, respondendo assim à principal questão de pesquisa colocada: *Que técnicas podemos utilizar para auxiliar na identificação*

de padrões dos participantes idosos no treinamento de jogos cognitivos computadorizados?

Cabe ressaltar que a principal limitação desta pesquisa é o fato de existirem poucas amostras disponíveis para uma investigação mais apurada, uma vez que os participantes ainda estão em treinamento. Contudo, mesmo com o quantitativo de 51 amostras, que só completaram as primeiras 20h de treinamento, foi possível obter padrões que demonstraram a eficácia desses treinos no que diz respeito a habilidades de memória, funcionalidade, atenção e velocidade de processamento.

Como trabalhos futuros, pretende-se aplicar os testes com um quantitativo maior de amostras para expandir os resultados e verificar se há melhoria nas diversas habilidades (memória, atenção, etc) considerando um tempo maior de treino (40h). Além disso, pretendemos expandir a investigação, aplicando a solução proposta em outros grupos de exames (habilidades cognitivas), por exemplo, linguagem, função executiva e cognição social. Retornando ao trabalho de Veloso et al. (2014) o qual também utilizou a técnica de clusterização para minerar dados, os autores realizaram uma preparação dos dados, a partir da criação de atributos derivados da base principal para criar uma escala (*score*) de avaliação de riscos que iria refletir na probabilidade de um determinado paciente retornar ou não a Unidade Intensiva. Nesse sentido, pode-se investigar a possibilidade da construção de uma escala de avaliação de desempenho para o treinamento cognitivo computadorizado e com isso a aplicação de algoritmos de mineração poderiam apresentar melhores resultados para a classificação de padrões.

Além disso, pode-se aplicar a métrica *Technology Readiness Level* (TRL) ao processo desenvolvido no contexto desta pesquisa. Esta métrica dá suporte a avaliações da maturidade de uma tecnologia específica e à comparação consistente de maturidade entre diferentes tipos de tecnologia (MANKINS, 1995). Com isso, seria possível verificar como as ferramentas e tecnologias pesquisadas, analisadas, selecionadas, desenvolvidas e aplicadas sobre os dados coletados com os especialistas do treinamento cognitivo (projeto Academia do Cérebro) se integram e compõem o processo (Figura 4.5) apresentado nesta dissertação. Esta métrica também poderia apontar diferenças socio-culturais inerentes aos participantes envolvidos no treinamento e no processo adotado.

Referências

ÁLVAREZ, S. et al. Applying Provenance in Distributed Organ Transplant Management. In: *Provenance and Annotation of Data. IPAW 2006. Lecture Notes in Computer Science, vol 4145*. Springer, Berlin, Heidelberg, 2006. p. 28–36. Disponível em: <<http://link.springer.com/10.1007/11890850>{\}.>

ANGUERA, J. A. et al. Video game training enhances cognitive control in older adults. *Nature*, Nature Publishing Group, a division of Macmillan Publishers Limited. All Rights Reserved., v. 501, n. 7465, p. 97–101, sep 2013. ISSN 1476-4687. Disponível em: <<http://dx.doi.org/10.1038/nature12486>>.

BASAK, C. et al. Can training in a real-time strategy video game attenuate cognitive decline in older adults? *Psychology and Aging*, v. 23, n. 4, p. 765–777, 2008. ISSN 1939-1498. Disponível em: <<http://doi.apa.org/getdoi.cfm?doi=10.1037/a0013494>>.

BERRY, M. J. A.; LINOFF, G. *Data mining techniques : for marketing, sales, and customer support*. 2ed. ed. Indianapolis, Indiana: Wiley, 2004. 672 p. ISBN 0471179809. Disponível em: <<https://dl.acm.org/citation.cfm?id=560675>>.

BOOCH, G.; RUMBAUGH, J.; JACOBSON, I. *UML Guia do Usuário*. Rio de Janeiro, RJ: Elsevier, 2005. 474 p.

BOONE, K. B.; LU, P.; WEN, J. Comparison of various RAVLT scores in the detection of noncredible memory performance. *Archives of Clinical Neuropsychology*, Oxford University Press, v. 20, n. 3, p. 301–319, may 2005. Disponível em: <<https://academic.oup.com/acn/article-lookup/doi/10.1016/j.acn.2004.08.001>>.

BRAINHQ. *About the BrainHQ Exercises*. 2018. Disponível em: <<https://www.brainhq.com/why-brainhq/about-the-brainhq-exercises>>.

Brasil. Presidência da República. Casa Civil. *Lei 10.741, de 1º de outubro de 2003. Dispõe sobre o Estatuto do Idoso e dá outras providências*. 2003. Disponível em: <<http://www.planalto.gov.br/ccivil/03/LEIS/2003/L10.741>>

BUNEMAN, P.; KHANNA, S.; TAN, W.-C. Data Provenance: Some Basic Issues. In: . Springer, Berlin, Heidelberg, 2000. p. 87–93. Disponível em: <<http://link.springer.com/10.1007/3-540-44450-5>{\}.>

BUNEMAN, P.; KHANNA, S.; WANG-CHIEW, T. Why and Where: A Characterization of Data Provenance. In: *8th International Conference on Database Theory*. London, UK: Springer, Berlin, Heidelberg, 2001. p. 316–330. Disponível em: <<http://link.springer.com/10.1007/3-540-44503-X>{\}_}>

CHI, H.; AGAMA, E.; PRODANOFF, Z. G. Developing serious games to promote cognitive abilities for the elderly. In: *2017 IEEE 5th International Conference on*

- Serious Games and Applications for Health (SeGAH)*. IEEE, 2017. p. 1–8. ISBN 978-1-5090-5482-4. Disponível em: <<http://ieeexplore.ieee.org/document/7939279/>>.
- COLENBRANDER, A.; RUNGE, P. Can Jaeger numbers be standardized. *Investigative Ophthalmology & Visual Science*, ARVO Annual Meeting abstract, v. 48, n. 13, p. 3563, 2007. ISSN 1552-5783. Disponível em: <<http://iovs.arvojournals.org/article.aspx?articleid=2386268{\&}resultClic>>.
- CRAEN, A. J. M. de; HEEREN, T. J.; GUSSEKLOO, J. Accuracy of the 15-item geriatric depression scale (GDS-15) in a community sample of the oldest old. *International Journal of Geriatric Psychiatry*, v. 18, n. 1, p. 63–66, jan 2003. ISSN 0885-6230. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/12497557http://doi.wiley.com/10.1002/gps.773>>.
- DINOV, I. D. Methodological challenges and analytic opportunities for modeling and interpreting Big Healthcare Data. *GigaScience*, v. 5, n. 1, p. 1, 2016. Disponível em: <[+http://dx.doi.org/10.1186/s13742-016-0117-6](http://dx.doi.org/10.1186/s13742-016-0117-6)>.
- ESPÍRITO-SANTO, H.; DANIEL, F. Calcular e apresentar tamanhos do efeito em trabalhos científicos (1): As limitações do $p < 0,05$ na análise de diferenças de médias de dois grupos. *Revista Portuguesa de Investigação Comportamental e Social*, v. 1, n. 1, p. 3–16, 2015.
- FRANTZIDIS, C. A. et al. Cognitive and physical training for the elderly: Evaluating outcome efficacy by means of neurophysiological synchronization. *International Journal of Psychophysiology*, Elsevier, v. 93, n. 1, p. 1–11, jul 2014. ISSN 0167-8760. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0167876014000361>>.
- FREIRE, J. et al. Provenance for Computational Tasks: A Survey. *Computing in Science & Engineering*, IEEE Educational Activities Department, v. 10, n. 3, p. 11–21, may 2008. ISSN 1521-9615. Disponível em: <<http://dl.acm.org/citation.cfm?id=1399086.1399195>>.
- GOEBEL, M.; GRUENWALD, L. A survey of data mining and knowledge discovery software tools. *ACM SIGKDD Explorations Newsletter*, ACM, v. 1, n. 1, p. 20–33, jun 1999. ISSN 19310145. Disponível em: <<http://portal.acm.org/citation.cfm?doid=846170.846172>>.
- GUERCIO, G. et al. Improving cognitive training for schizophrenia using neuroplasticity enhancers: Lessons from decades of basic and clinical research. *Schizophrenia Research*, Elsevier, may 2018. ISSN 0920-9964. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S092099641830241X>>.
- HE, S. et al. Game Player Strategy Pattern Recognition by Using Radial Basis Function. In: *2008 International Conference on Computer Science and Software Engineering*. IEEE, 2008. p. 937–940. ISBN 978-0-7695-3336-0. Disponível em: <<http://ieeexplore.ieee.org/document/4721904/>>.
- HUPPERT, F. A. et al. CAMCOG-A concise neuropsychological test to assist dementia diagnosis: Socio-demographic determinants in an elderly population sample. *British Journal of Clinical Psychology*, Wiley/Blackwell (10.1111), v. 34, n. 4, p. 529–541, nov 1995. ISSN 01446657. Disponível em: <<http://doi.wiley.com/10.1111/j.2044-8260.1995.tb01487.x>>.

- IBGE. Instituto Brasileiro de Geografia e Estatística. *Projeções da População*. 2018. Disponível em: <<https://www.ibge.gov.br/estatisticas-novoportal/sociais/populacao/9109-projecao-da-populacao.html?=&t=o-qu>>.
- JACOB, L. B. *Spielzyklus: Identificando Padrões de Ciclos em Dados de Proveniência Extraídos de Forma não Intrusiva*. 63 p. Tese (Dissertação de Mestrado) — Universidade Federal Fluminense, 2015.
- JAIN, A. K.; MURTY, M. N.; FLYNN, P. J. Data clustering: a review. *ACM Computing Surveys*, ACM, v. 31, n. 3, p. 264–323, sep 1999. ISSN 03600300. Disponível em: <<http://portal.acm.org/citation.cfm?doid=331499.331504>>.
- JOTHI, N.; RASHID, N. A.; HUSAIN, W. Data Mining in Healthcare – A Review. *Procedia Computer Science*, Elsevier, v. 72, p. 306–313, jan 2015. ISSN 1877-0509. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1877050915036066>>.
- KARLINI, D.; RIGO, S. J. ABCLINGO: Integrando Jogos Sérios e Mineração de Dados Educacionais no Apoio ao Letramento. In: *XIII Simpósio Brasileiro de Jogos e Entretenimento Digital (SBGames)*. Porto Alegre, RS: [s.n.], 2014. p. 1149–1152.
- KEMPLER, D. et al. The effects of age, education, and ethnicity on verbal fluency. *Journal of the International Neuropsychological Society*, v. 4, n. 6, p. 531–538, 1998.
- KLINGBERG, T. Training and plasticity of working memory. *Trends in Cognitive Sciences*, v. 14, n. 7, p. 317–324, 2010. ISSN 1364-6613. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1364661310000938>>.
- KUEIDER, A. M. et al. Computerized Cognitive Training with Older Adults: A Systematic Review. *PLoS ONE*, Public Library of Science, v. 7, n. 7, p. e40588, jul 2012. ISSN 1932-6203. Disponível em: <<https://dx.plos.org/10.1371/journal.pone.0040588>>.
- LAWTON, M. P.; BRODY, E. M. Assessment of older people: Self-maintaining and instrumental activities of daily living. *Gerontologist*, The Gerontological Society of America, v. 9, n. 3, p. 179–186, 1969. Disponível em: <<https://doi.org/10.1093/geront/9.3>>.
- LIM, C. et al. Prospective and Retrospective Provenance Collection in Scientific Workflow Environments. In: *2010 IEEE International Conference on Services Computing*. IEEE, 2010. p. 449–456. ISBN 978-1-4244-8147-7. Disponível em: <<http://ieeexplore.ieee.org/document/5557202/>>.
- LIMA-COSTA, M. F.; VERAS, R. Saúde pública e envelhecimento. *Cadernos de Saúde Pública*, Escola Nacional de Saúde Pública, Fundação Oswaldo Cruz, v. 19, n. 3, p. 700–701, jun 2003. ISSN 0102-311X. Disponível em: <<http://www.scielo.br/scielo.php?script=sciarttext&pid=S0102-311X2003000300001&lng=p>>.
- MAIER, L. J. et al. Swiss University Students' Attitudes toward Pharmacological Cognitive Enhancement. *PLOS ONE*, Public Library of Science, v. 10, n. 12, p. e0144402, dec 2015. ISSN 1932-6203. Disponível em: <<http://dx.plos.org/10.1371/journal.pone.0144402>>.

- MANKINS, J. C. *Technology Readiness Levels*. 1995. 5 p. Disponível em: <[https://www.sciencedirect.com/science/article/pii/S0957417412009955](https://aiaa.kavi.com/apps/group{_}public/download.php/2212/TRLs{_}MankinsPaper{_}.>></p><p>MAO, R.; CHEN, C.; LI, D. Intervention effect of BrainHQ visual training on depressive symptom In subjects with post stroke depression. <i>Chinese Journal of Behavioral Medicine and Brain Science</i>, v. 24, n. 12, p. 1097–1099, 2015.</p><p>MARCANO-CEDENO, A. et al. Data mining applied to the cognitive rehabilitation of patients with acquired brain injury. <i>Expert Systems with Applications</i>, Pergamon, v. 40, n. 4, p. 1054–1060, mar 2013. ISSN 0957-4174. Disponível em: <.
- MCDOUGALL, G. J. et al. The revised direct assessment of functional status for independent older adults. *Gerontologist*, The Gerontological Society of America, v. 50, n. 3, p. 363–370, 2010. ISSN 1758-5341. Disponível em: <<https://doi.org/10.1093/geront/gnp139>>.
- MIELKE, M. M. et al. Performance of the CogState computerized battery in the Mayo Clinic Study on Aging. *Alzheimer's & Dementia*, v. 11, n. 11, p. 1367–1376, 2015. ISSN 1552-5260. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1552526015000862>>.
- NARDI, L.; TREVISAN, D.; OLIVEIRA, D. de. A Provenance-based Approach to Support Cognitive Training of the Elderly Using Serious Games. *Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS_CSBC)*, v. 18, n. 1/2018, 2018. Disponível em: <<http://portaldeconteudo.sbc.org.br/index.php/sbcas/article/view/3675>>.
- NETTO, T. M. Treinamento cognitivo da memória de trabalho em adultos idosos. *Psicologia Clínica*, scieloepsic, v. 22, p. 218, 2010. ISSN 0103-5665. Disponível em: <[http://www.ncbi.nlm.nih.gov/pubmed/12053117](http://pepsic.bvsalud.org/scielo.php?script=sci{_}arttext{\\&}pid=S0103-56652010000200021{_}.>></p><p>OWSLEY, C. et al. Timed instrumental activities of daily living tasks: relationship to cognitive function and everyday performance assessments in older adults. <i>Gerontology</i>, Karger Publishers, v. 48, n. 4, p. 254–65, 2002. ISSN 0304-324X. Disponível em: <.
- PANDEY, S. C. Data mining techniques for medical data: A review. In: *2016 International Conference on Signal Processing, Communication, Power and Embedded System (SCOPES)*. IEEE, 2016. p. 972–982. ISBN 978-1-5090-4620-1. Disponível em: <<http://ieeexplore.ieee.org/document/7955586/>>.
- PANIZZUTTI, R.; HAMILTON, S. P.; VINOGRADOV, S. Genetic correlate of cognitive training response in schizophrenia. *Neuropharmacology*, Pergamon, v. 64, p. 264–267, jan 2013. ISSN 0028-3908. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0028390812003978>>.
- PEEL, N. M.; BARTLETT, H. P.; MARSHALL, A. L. Measuring quality of life in older people: Reliability and validity of WHOQOL-OLD. *Australasian Journal on Ageing*, Wiley/Blackwell (10.1111), v. 26, n. 4, p. 162–167, dec 2007. ISSN 1440-6381. Disponível em: <<http://doi.wiley.com/10.1111/j.1741-6612.2007.00249.x>>.

POWER, M. Development of the World Health Organization WHOQOL-BREF Quality of Life Assessment. *Psychological Medicine*, v. 28, n. 3, p. 551–558, 1998.

RASMUSSEN, X. D. et al. Effects of Age and Dementia on the Trail Making Test. *The Clinical Neuropsychologist*, Taylor & Francis Group, v. 12, n. 2, p. 169–178, may 1998. ISSN 1385-4046. Disponível em: <<https://www.tandfonline.com/doi/full/10.1076/clin.12.2.169.2005>>.

RECKER, J. *Scientific research in information systems : a beginner's guide*. [S.l.]: Springer, 2013. ISBN 9783642300479.

RUSCIO, J.; MULLEN, T. Confidence Intervals for the Probability of Superiority Effect Size Measure and the Area Under a Receiver Operating Characteristic Curve. *Multivariate Behavioral Research*, Taylor & Francis Group, v. 47, n. 2, p. 201–223, mar 2012. ISSN 0027-3171. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/00273171.2012.658329>>.

Shawn Green, C. et al. Improving Methodological Standards in Behavioral Interventions for Cognitive Enhancement. *Journal of Cognitive Enhancement*, Springer International Publishing, p. 1–28, jan 2019. ISSN 2509-3290. Disponível em: <<http://link.springer.com/10.1007/s41465-018-0115-y>>.

SHELKEY, M.; WALLACE, M. Katz index of independence in activities of daily living. *Journal of Gerontological Nursing*, v. 25, n. 3, p. 8–9, 1999.

TOMBAUGH, T. N.; MCINTYRE, N. J. The Mini-Mental State Examination: A Comprehensive Review. *Journal of the American Geriatrics Society*, Wiley/Blackwell (10.1111), v. 40, n. 9, p. 922–935, sep 1992. ISSN 00028614. Disponível em: <<http://doi.wiley.com/10.1111/j.1532-5415.1992.tb01992.x>>.

United Nations. Department of Economic and Social Affairs. Population Division. *World Population Prospects: The 2017 Revision, Key Findings and Advance Tables*. New York, NY: [s.n.], 2017. 53 p. Disponível em: <https://population.un.org/wpp/Publications/Files/WPP2017{__}KeyFindings.>

VARGHA, A.; DELANEY, H. D. A Critique and Improvement of the CL Common Language Effect Size Statistics of McGraw and Wong. *Journal of Educational and Behavioral Statistics*, SAGE PublicationsSage CA: Los Angeles, CA, v. 25, n. 2, p. 101–132, jun 2000. Disponível em: <<http://journals.sagepub.com/doi/10.3102/10769986025002101>>.

VELOSO, R. et al. A Clustering Approach for Predicting Readmissions in Intensive Medicine. *Procedia Technology*, Elsevier, v. 16, p. 1307–1316, jan 2014. ISSN 2212-0173. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2212017314003740>>.

W3C. *PROV-DM: The PROV Data Model*. 2013. Disponível em: <<https://www.w3.org/TR/prov-dm/>>.

Weka Project. *Class SimpleKMeans*. 2018. Disponível em: <<http://weka.sourceforge.net/doc.dev/weka/clusterers/SimpleKMeans.html>>.

WHITLOCK, L. A.; MCLAUGHLIN, A. C.; ALLAIRE, J. C. Individual differences in response to cognitive training: Using a multi-modal, attentionally demanding game-based intervention for older adults. *Computers in Human Behavior*, Pergamon, v. 28, n. 4, p. 1091–1096, jul 2012. ISSN 0747-5632. Disponível em: <<https://www-sciencedirect.ez39.periodicos.capes.gov.br/science/article/pii/S0747563212000143>>.

WHO. World Health Organization. *World report on Ageing and Health*. Geneva, Switzerland: [s.n.], 2015. 260 p. Disponível em: <http://apps.who.int/iris/bitstream/handle/10665/186463/9789240694811{_}eng.>

WILLIAMS, K. N.; KEMPER, S. Exploring Interventions to Reduce Cognitive Decline in Aging. In: _____. *Journal of psychosocial nursing and mental health services*. [S.l.: s.n.], 2010. v. 48, n. 5, p. 42–51.

APÊNDICE A - Clusters e padrões encontrados para K=5 (exames grupo Memória)

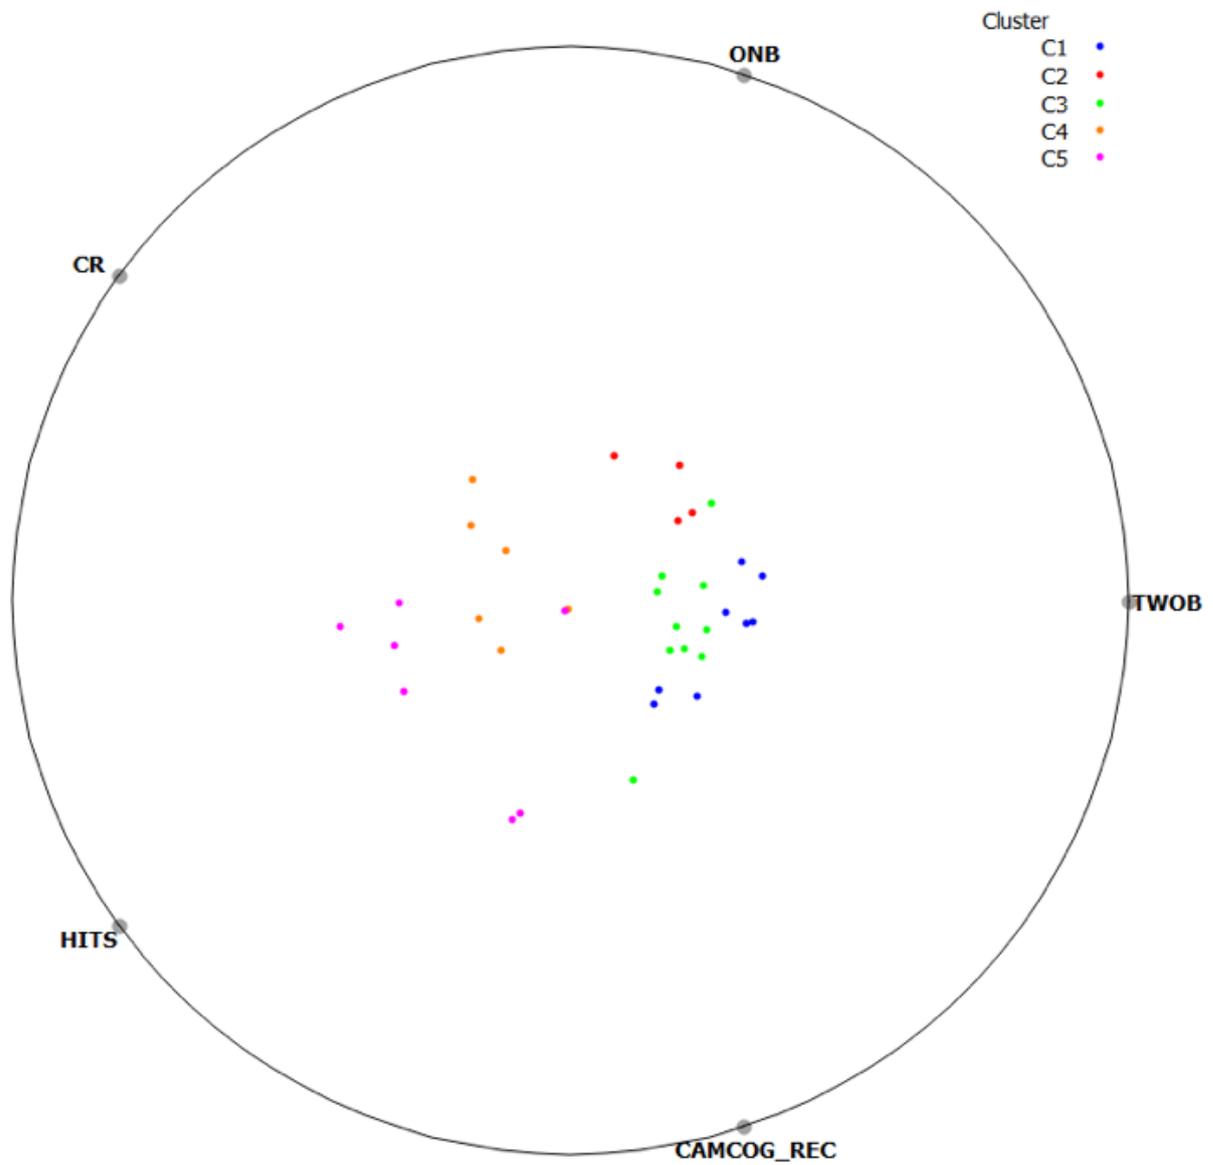


Figura A.1: Clusters gerados para os exames do grupo memória, considerando K=5

Tabela A.1: Padrão encontrado para o cluster C1 e K=5. Exames do grupo Memória. Total: 08 participantes

| Exame | Padrão | Relação N/T | % | Participantes (Abordagem) |
|------------|-----------------------|-------------|------|--|
| ONB | Piorou (AV2 > AV1) | 8/8 | 100 | P3(BU), P6(BU), P13(BU), P15(BU), P46(BU), P14(TD), P28(TD), P95(TD) |
| TWOB | Melhorou (AV2 >= AV1) | 8/8 | 100 | P3(BU), P6(BU), P13(BU), P15(BU), P46(BU), P14(TD), P28(TD), P95(TD) |
| CAMCOG_REC | Melhorou (AV2 >= AV1) | 8/8 | 100 | P3(BU), P6(BU), P13(BU), P15(BU), P46(BU), P14(TD), P28(TD), P95(TD) |
| HITS | Piorou (AV2 < AV1) | 5/8 | 62,5 | P6(BU), P15(BU), P46(BU), P14(TD), P28(TD) |
| CR | Piorou (AV2 < AV1) | 8/8 | 100 | P3(BU), P6(BU), P13(BU), P15(BU), P46(BU), P14(TD), P28(TD), P95(TD) |

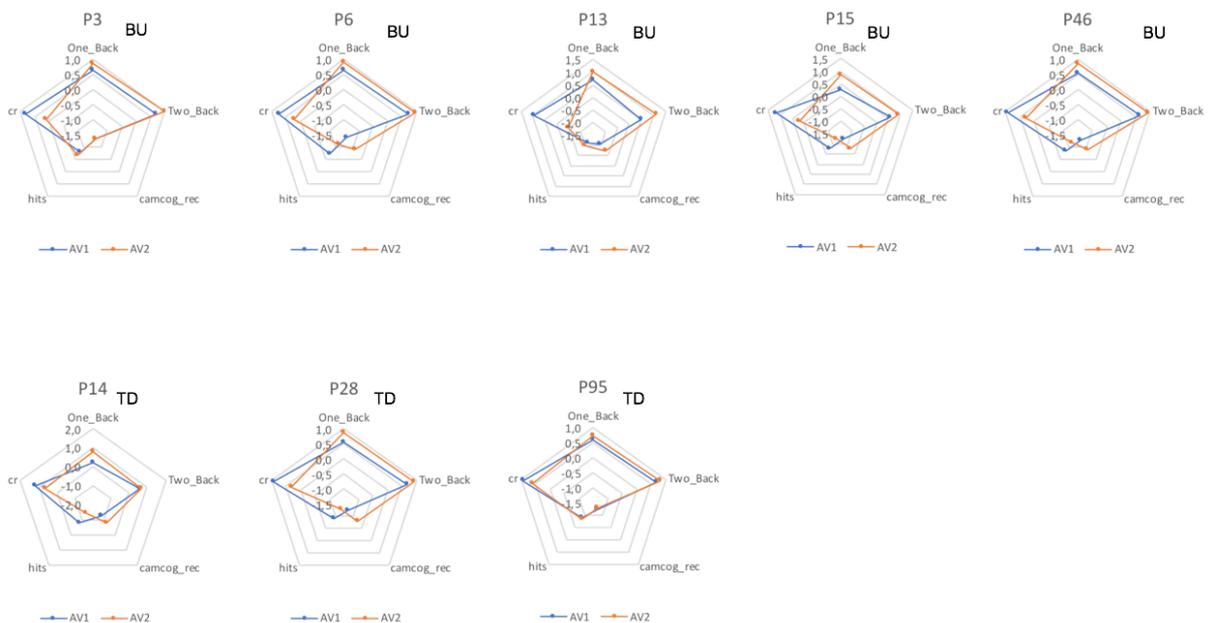


Figura A.2: Gráficos radar de cada participantes do cluster C1 (K=5). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja)

Tabela A.2: Padrão encontrado para o cluster C2 e K=5. Exames do grupo Memória. Total: 4 participantes

| Exame | Padrão | Relação N/T | % | Participantes (Abordagem) |
|------------|-----------------------|-------------|-----|-------------------------------------|
| ONB | Piorou (AV2 > AV1) | 2/4 | 50 | P76(TD), P61(TD) |
| TWOB | Melhorou (AV2 >= AV1) | 3/4 | 75 | P108(BU), P24(TD), P76(TD) |
| CAMCOG_REC | Melhorou (AV2 >= AV1) | 4/4 | 100 | P108(BU), P24(TD), P76(TD), P61(TD) |
| HITS | Piorou (AV2 < AV1) | 3/4 | 75 | P24(TD), P76(TD), P61(TD) |
| CR | Piorou (AV2 > AV1) | 2/4 | 50 | P76(TD), P61(TD) |

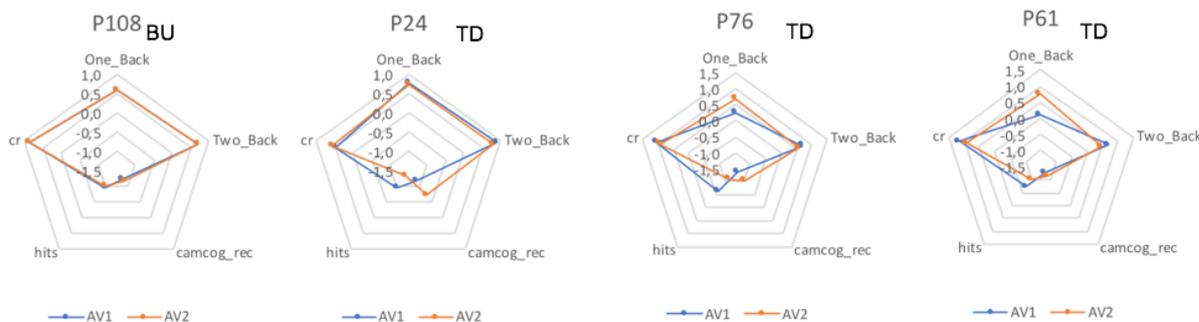


Figura A.3: Gráficos radar de cada participantes do cluster C2 (K=5). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja)

Tabela A.3: Padrão encontrado para o cluster C3 e K=5. Exames do grupo Memória. Total: 10 participantes

| Exame | Padrão | Relação N/T | % | Participantes (Abordagem) |
|------------|-----------------------|-------------|-----|--|
| ONB | Melhorou (AV2 <= AV1) | 9/10 | 90 | P26(BU), P32(BU), P41(BU), P44(BU), P111(BU), P22(TD), P50(TD), P55(TD), P112(TD) |
| TWOB | Melhorou (AV2 >= AV1) | 10/10 | 100 | P26(BU), P32(BU), P41(BU), P44(BU), P111(BU), P22(TD), P50(TD), P36(TD), P55(TD), P112(TD) |
| CAMCOG_REC | Piorou (AV2 < AV1) | 7/10 | 70 | P32(BU), P41(BU), P44(BU), P50(TD), P36(TD), P55(TD), P112(TD) |
| HITS | Piorou (AV2 < AV1) | 6/10 | 60 | P32(BU), P41(BU), P44(BU), P50(TD), P36(TD), P112(TD) |
| CR | Piorou (AV2 > AV1) | 7/10 | 70 | P26(BU), P32(BU), P41(BU), P44(BU), P50(TD), P36(TD), P112(TD) |

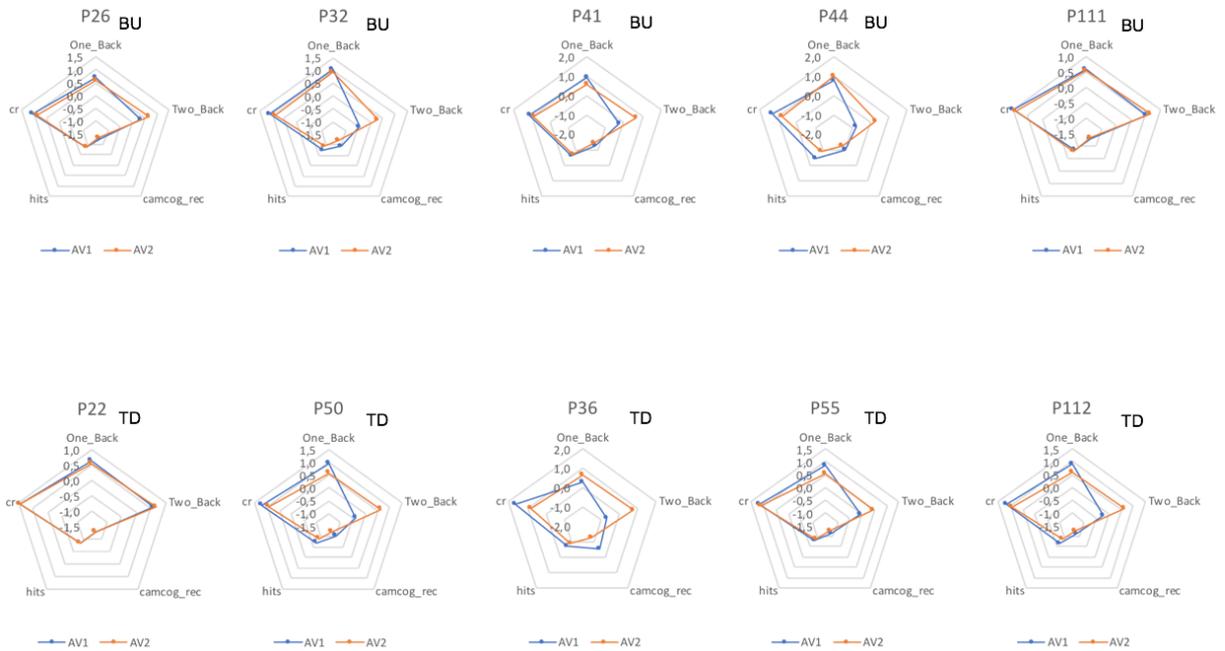


Figura A.4: Gráficos radar de cada participantes do cluster C3 (K=5). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja)

Tabela A.4: Padrão encontrado para o cluster C4 e K=5. Exames do grupo Memória. Total: 6 participantes

| Exame | Padrão | Relação N/T | % | Participantes (Abordagem) |
|----------|-----------------------|-------------|------|---|
| ONB | Melhorou (AV2 <= AV1) | 6/6 | 100 | P34(BU), P71(TD), P87(BU), P101(BU), P38(TD), P63(TD) |
| TWOB | Melhorou (AV2 >= AV1) | 5/6 | 83,3 | P34(BU), P71(TD), P87(BU), P101(BU), P63(TD) |
| CAMCOG | Melhorou (AV2 <= AV1) | 6/6 | 100 | P34(BU), P71(TD), P87(BU), P101(BU), P38(TD), P63(TD) |
| HITS_REC | Melhorou (AV2 >= AV1) | 4/6 | 66,7 | P71(TD), P87(BU), P101(BU), P63(TD) |
| CR | Melhorou (AV2 <= AV1) | 6/6 | 100 | P34(BU), P71(TD), P87(BU), P101(BU), P38(TD), P63(TD) |

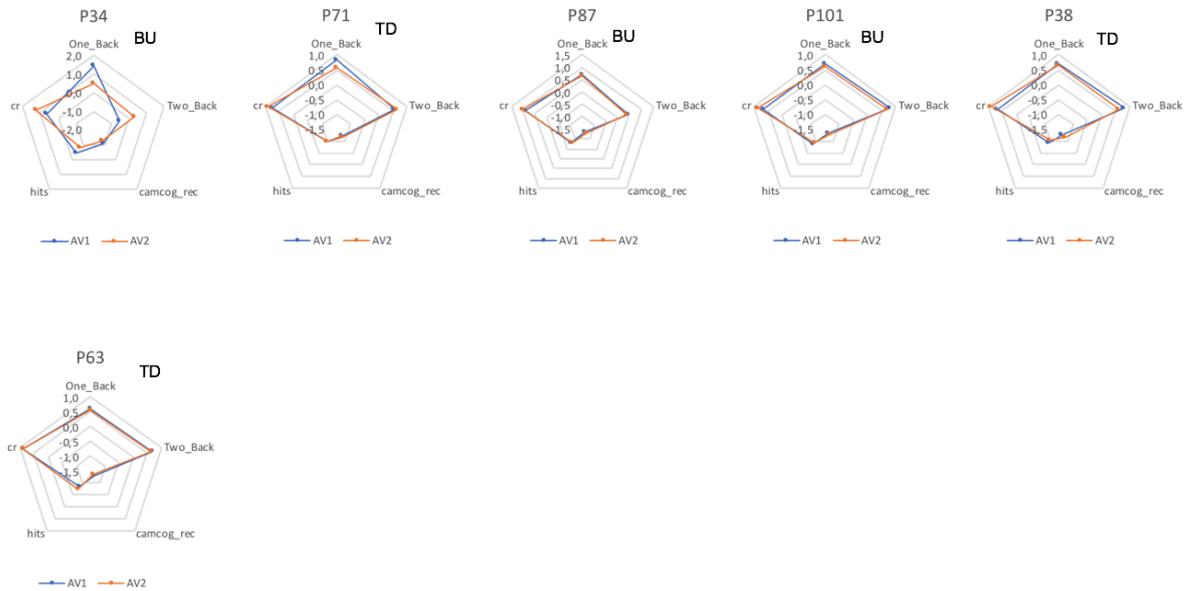


Figura A.5: Gráficos radar de cada participantes do cluster C4 (K=5). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja)

Tabela A.5: Padrão encontrado para o cluster C5 e K=5. Exames do grupo Memória. Total: 7 participantes

| Exame | Padrão | Relação N/T | % | Participantes (Abordagem) |
|------------|-----------------------|-------------|------|--|
| ONB | Melhorou (AV2 <= AV1) | 7/7 | 100 | P39(BU), P62(BU), P64(BU), P104(BU), P105(BU), P66(TD), P110(TD) |
| TWOB | Piorou (AV2 < AV1) | 4/7 | 57,1 | P39(BU), P62(BU), P64(BU), P110(TD) |
| CAMCOG_REC | Melhorou (AV2 <= AV1) | 7/7 | 100 | P39(BU), P62(BU), P64(BU), P104(BU), P105(BU), P66(TD), P110(TD) |
| HITS | Melhorou (AV2 <= AV1) | 7/7 | 100 | P39(BU), P62(BU), P64(BU), P104(BU), P105(BU), P66(TD), P110(TD) |
| CR | Melhorou (AV2 <= AV1) | 7/7 | 100 | P39(BU), P62(BU), P64(BU), P104(BU), P105(BU), P66(TD), P110(TD) |

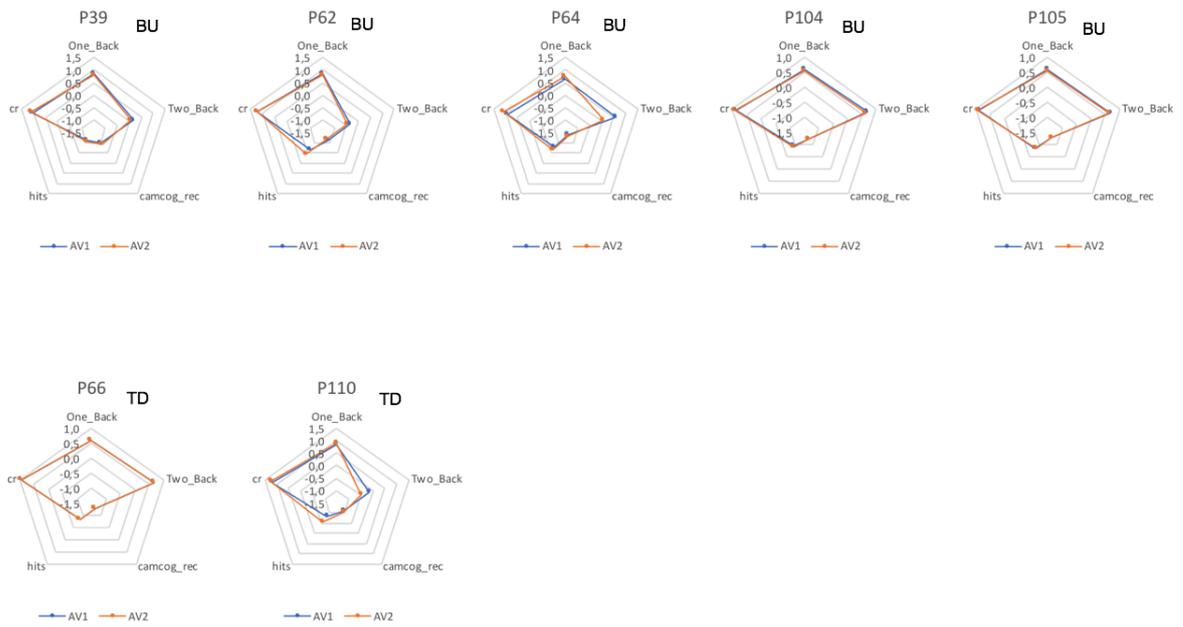


Figura A.6: Gráficos radar de cada participantes do cluster C5 (K=5). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja)

APÊNDICE B - Clusters e padrões encontrados para K=7 (exames grupo Memória)

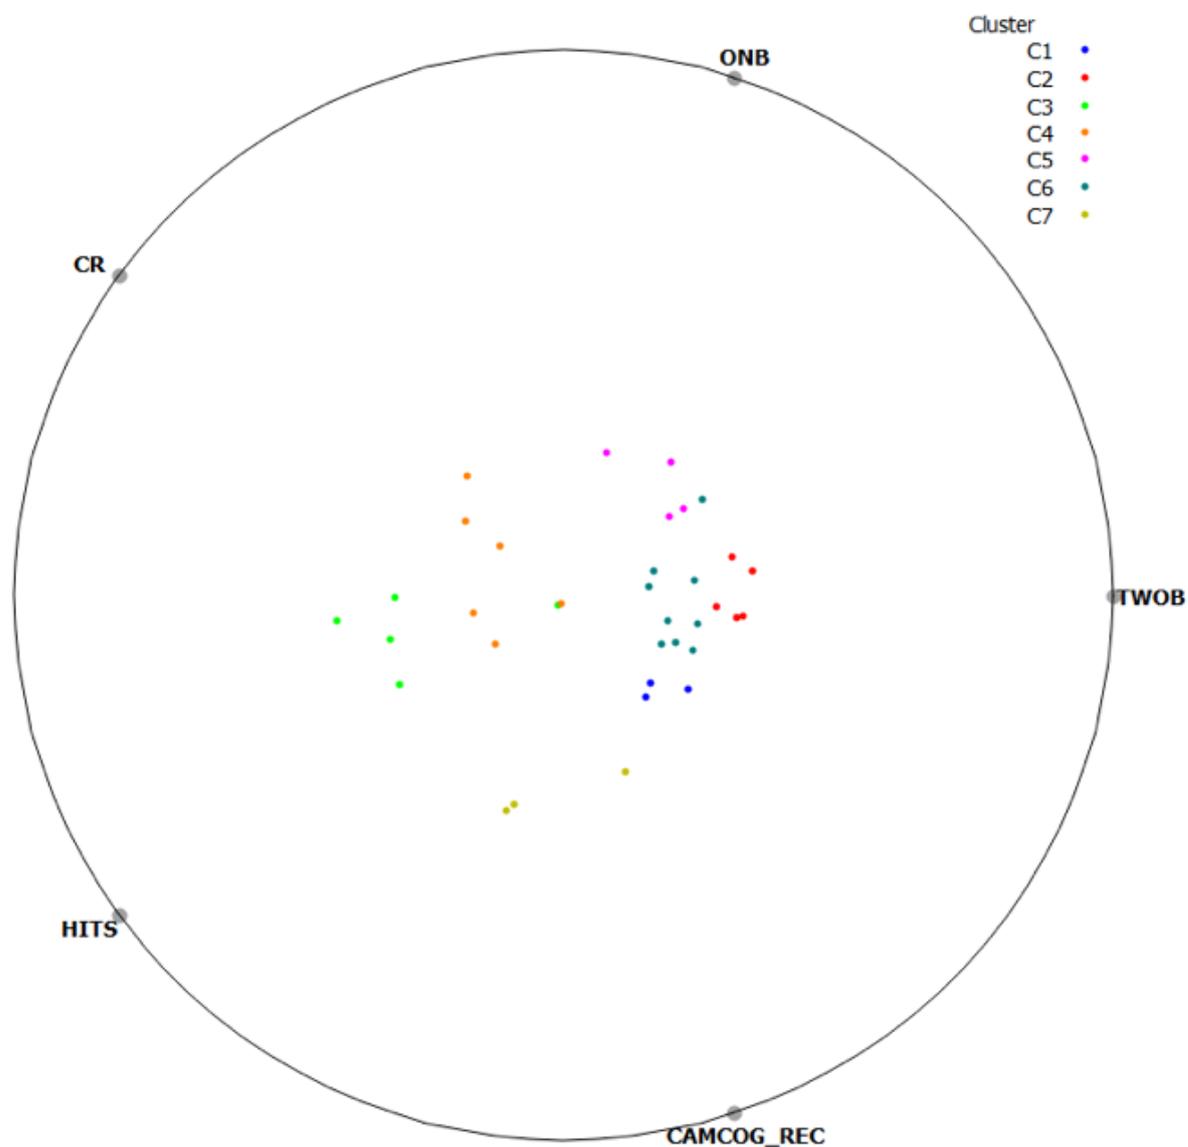


Figura B.1: Clusters gerados para os exames do grupo memória, considerando K=7

Tabela B.1: Padrão encontrado para o cluster C1 e K=7. Exames do grupo Memória. Total: 3 participantes

| Exame | Padrão | Relação N/T | % | Participantes (Abordagem) |
|------------|-----------------------|-------------|-----|---------------------------|
| ONB | Melhorou (AV2 <= AV1) | 3/3 | 100 | P3(BU), P13(BU), P95(TD) |
| TWOB | Melhorou (AV2 >= AV1) | 3/3 | 100 | P3(BU), P13(BU), P95(TD) |
| CAMCOG_REC | Melhorou (AV2 >= AV1) | 3/3 | 100 | P3(BU), P13(BU), P95(TD) |
| HITS | Melhorou (AV2 >= AV1) | 3/3 | 100 | P3(BU), P13(BU), P95(TD) |
| CR | Piorou (AV2 < AV1) | 3/3 | 100 | P3(BU), P13(BU), P95(TD) |

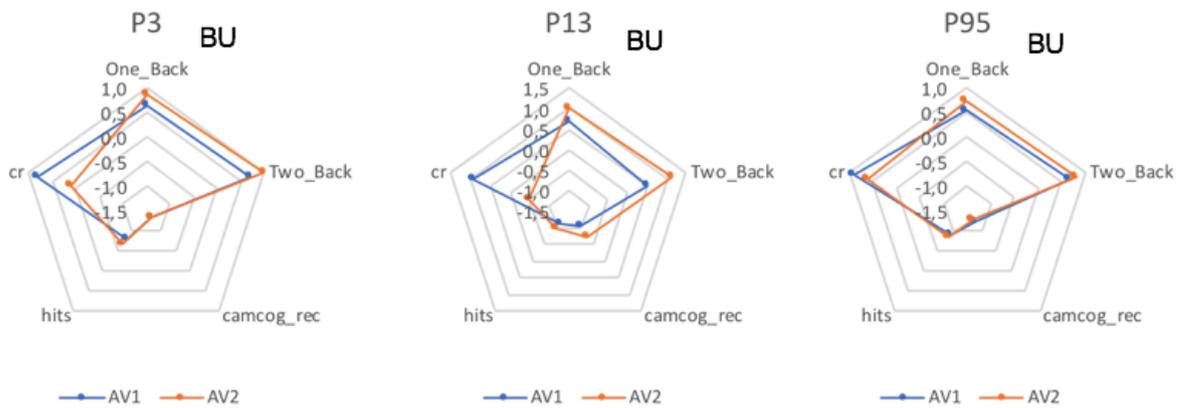


Figura B.2: Gráficos radar de cada participante do cluster C1 (K=7). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja)

Tabela B.2: Padrão encontrado para o cluster C2 e K=7. Exames do grupo Memória. Total: 5 participantes

| Exame | Padrão | Relação N/T | % | Participantes (Abordagem) |
|------------|-----------------------|-------------|-----|--|
| ONB | Piorou (AV2 > AV1) | 5/5 | 100 | P6(BU), P15(BU), P46(BU), P14(TD), P28(TD) |
| TWOB | Melhorou (AV2 >= AV1) | 5/5 | 100 | P6(BU), P15(BU), P46(BU), P14(TD), P28(TD) |
| CAMCOG_REC | Melhorou (AV2 >= AV1) | 5/5 | 100 | P6(BU), P15(BU), P46(BU), P14(TD), P28(TD) |
| HITS | Piorou (AV2 < AV1) | 5/5 | 100 | P6(BU), P15(BU), P46(BU), P14(TD), P28(TD) |
| CR | Piorou (AV2 > AV1) | 5/5 | 100 | P6(BU), P15(BU), P46(BU), P14(TD), P28(TD) |

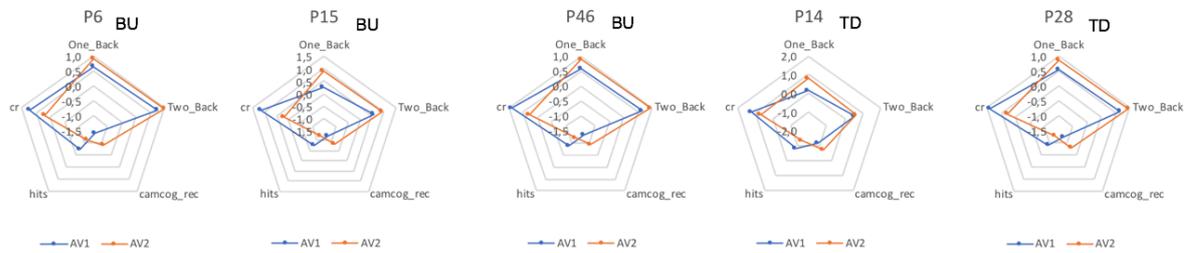


Figura B.3: Gráficos radar de cada participante do cluster C2 (K=7). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja)

Tabela B.3: Padrão encontrado para o cluster C3 e K=7. Exames do grupo Memória. Total: 5 participantes

| Exame | Padrão | Relação N/T | % | Participantes (Abordagem) |
|------------|-----------------------|-------------|-----|---|
| ONB | Melhorou (AV2 <= AV1) | 5/5 | 100 | P39(BU), P64(BU), P104(BU), P66(TD), P110(TD) |
| TWOB | Piorou (AV2 < AV1) | 3/5 | 60 | P39(BU), P64(BU), P110(TD) |
| CAMCOG_REC | Melhorou (AV2 >= AV1) | 5/5 | 100 | P39(BU), P64(BU), P104(BU), P66(TD), P110(TD) |
| HITS | Melhorou (AV2 >= AV1) | 5/5 | 100 | P39(BU), P64(BU), P104(BU), P66(TD), P110(TD) |
| CR | Melhorou (AV2 <= AV1) | 5/5 | 100 | P39(BU), P64(BU), P104(BU), P66(TD), P110(TD) |

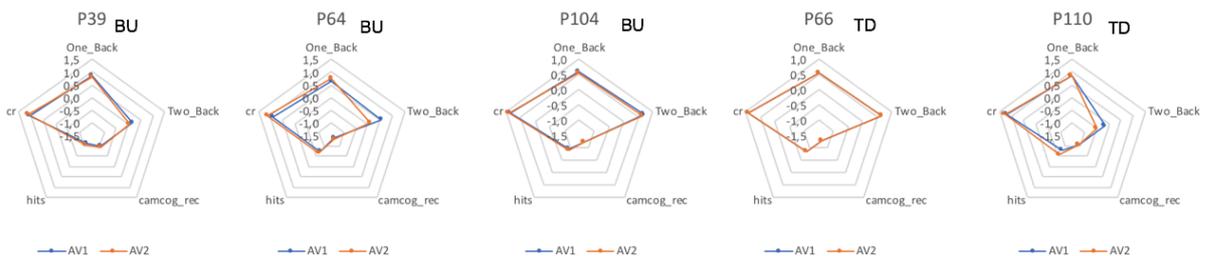


Figura B.4: Gráficos radar de cada participante do cluster C3 (K=7). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja)

Tabela B.4: Padrão encontrado para o cluster C4 e K=7. Exames do grupo Memória. Total: 6 participantes

| Exame | Padrão | Relação N/T | % | Participantes (Abordagem) |
|------------|-----------------------|-------------|------|---|
| ONB | Melhorou (AV2 <= AV1) | 6/6 | 100 | P34(BU), P71(TD), P87(BU), P101(BU), P38(TD), P63(TD) |
| TWOB | Melhorou (AV2 >= AV1) | 5/6 | 83,3 | P34(BU), P71(TD), P87(BU), P101(BU), P63(TD) |
| CAMCOG_REC | Melhorou (AV2 <= AV1) | 6/6 | 100 | P34(BU), P71(TD), P87(BU), P101(BU), P38(TD), P63(TD) |
| HITS | Melhorou (AV2 >= AV1) | 4/6 | 66,7 | P71(TD), P87(BU), P101(BU), P63(TD) |
| CR | Melhorou (AV2 <= AV1) | 6/6 | 100 | P34(BU), P71(TD), P87(BU), P101(BU), P38(TD), P63(TD) |

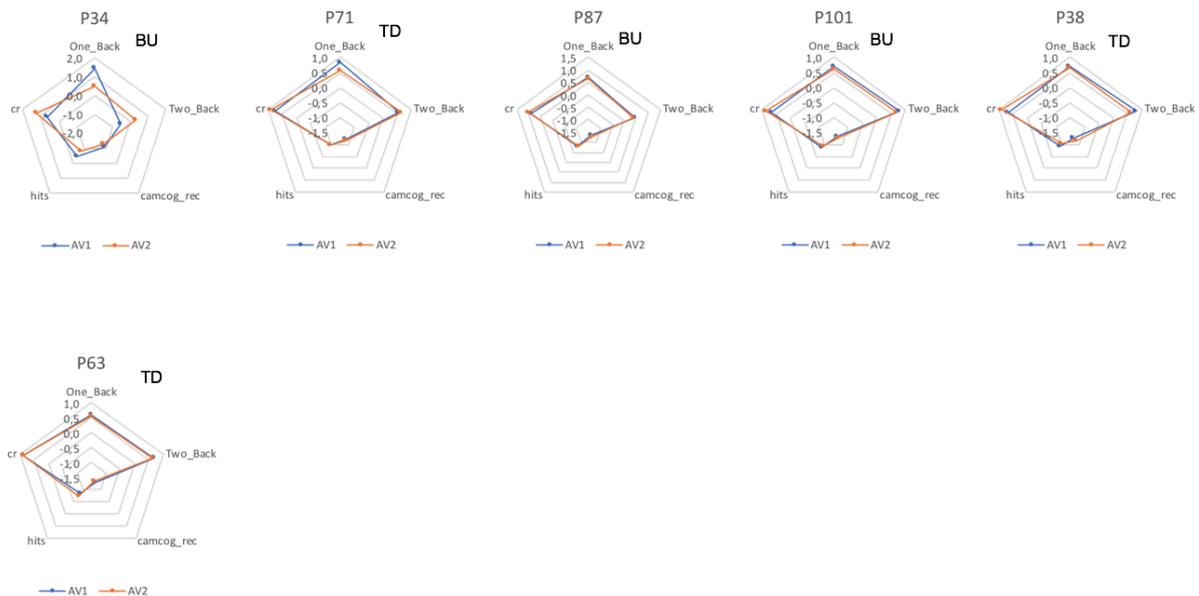


Figura B.5: Gráficos radar de cada participantes do cluster C4 (K=7). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja)

Tabela B.5: Padrão encontrado para o cluster C5 e K=7. Exames do grupo Memória. Total: 4 participantes

| Exame | Padrão | Relação N/T | % | Participantes (Abordagem) |
|------------|-----------------------|-------------|-----|-------------------------------------|
| ONB | Melhorou (AV2 <= AV1) | 2/4 | 50 | P108(BU), P24(TD) |
| TWOB | Piorou (AV2 < AV1) | 3/4 | 75 | P24(TD), P76(TD), P61(TD) |
| CAMCOG_REC | Melhorou (AV2 <= AV1) | 4/4 | 100 | P108(BU), P24(TD), P76(TD), P61(TD) |
| HITS | Piorou (AV2 < AV1) | 3/4 | 75 | P24(TD), P76(TD), P61(TD) |
| CR | Melhorou (AV2 <= AV1) | 2/4 | 50 | P108(BU), P24(BU) |

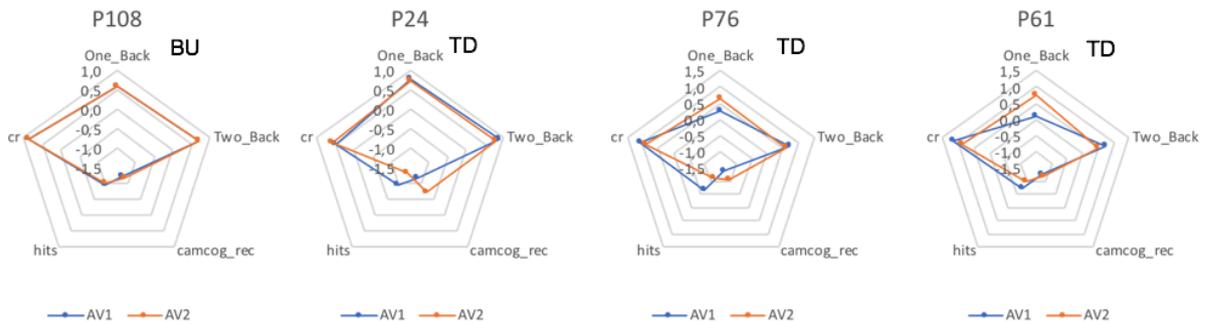


Figura B.6: Gráficos radar de cada participantes do cluster C5 (K=7). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja)

Tabela B.6: Padrão encontrado para o cluster C6 e K=7. Exames do grupo Memória. Total: 9 participantes

| Exame | Padrão | Relação N/T | % | Participantes (Abordagem) |
|------------|-----------------------|-------------|------|---|
| ONB | Melhorou (AV2 <= AV1) | 8/9 | 88,9 | P26(BU), P32(BU), P41(BU), P44(BU), P111(BU), P22(TD), P50(TD), P112(TD) |
| TWOB | Melhorou (AV2 >= AV1) | 9/9 | 100 | P26(BU), P32(BU), P41(BU), P44(BU), P111(BU), P22(TD), P50(TD), P36(TD), P112(TD) |
| CAMCOG_REC | Piorou (AV2 < AV1) | 6/9 | 66,7 | P32(BU), P41(BU), P44(BU), P50(TD), P36(TD), P112(TD) |
| HITS | Piorou (AV2 < AV1) | 6/9 | 66,7 | P32(BU), P41(BU), P44(BU), P50(TD), P36(TD), P112(TD) |
| CR | Piorou (AV2 < AV1) | 7/9 | 77,8 | P26(BU), P32(BU), P41(BU), P44(BU), P50(TD), P36(TD), P112(TD)) |

Tabela B.7: Padrão encontrado para o cluster C7 e K=7. Exames do grupo Memória. Total: 3 participantes

| Exame | Padrão | Relação N/T | % | Participantes (Abordagem) |
|------------|-----------------------|-------------|------|----------------------------|
| ONB | Melhorou (AV2 <= AV1) | 3/3 | 100 | P62(BU), P105(BU), P55(TD) |
| TWOB | Melhorou (AV2 <= AV1) | 3/3 | 100 | P62(BU), P105(BU), P55(TD) |
| CAMCOG_REC | Melhorou (AV2 <= AV1) | 2/3 | 66,6 | P62(BU), P105(BU) |
| HITS | Melhorou (AV2 <= AV1) | 3/3 | 100 | P62(BU), P105(BU), P55(TD) |
| CR | Melhorou (AV2 <= AV1) | 3/3 | 100 | P62(BU), P105(BU), P55(TD) |

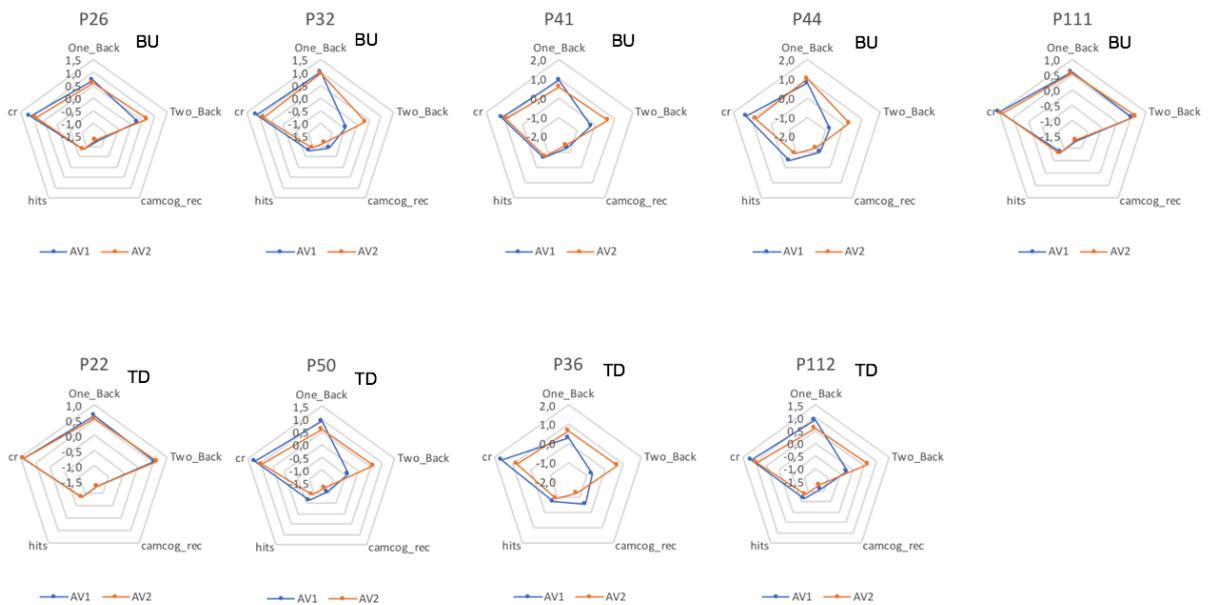


Figura B.7: Gráficos radar de cada participante do cluster C6 (K=7). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja)

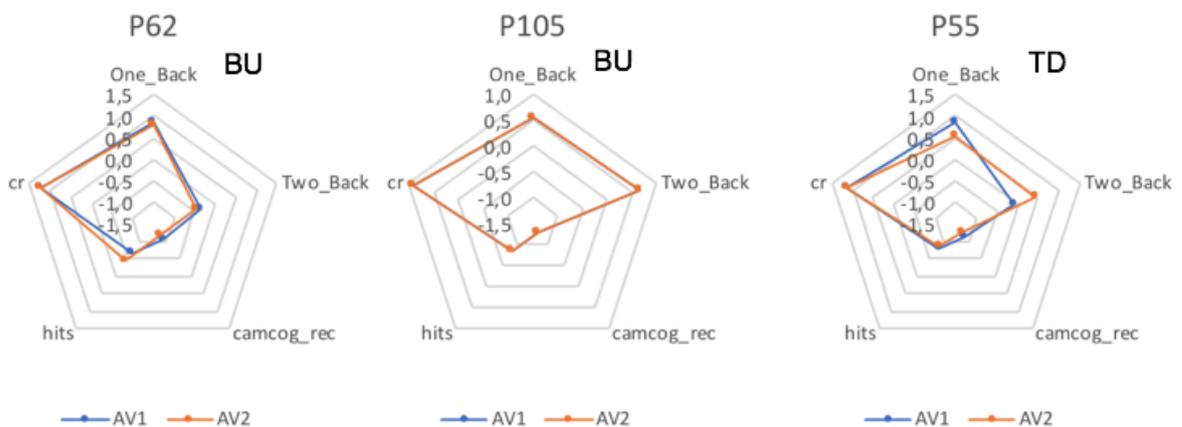


Figura B.8: Gráficos radar de cada participante do cluster C7 (K=7). Pontuações nos exames do grupo memória. Avaliações AV1 (em azul) e AV2 (em laranja)