



**UNIVERSIDADE ESTADUAL DE CAMPINAS**

Faculdade de Engenharia Elétrica e de Computação

**Luiz Carlos Pinheiro Junior**

**Algoritmos de Emparelhamento Estável para Otimização  
de Geração de Pares em Jogos Educacionais e Outros  
Cenários**

Campinas

2025

**Luiz Carlos Pinheiro Junior**

**Algoritmos de Emparelhamento Estável para Otimização  
de Geração de Pares em Jogos Educacionais e Outros  
Cenários**

Tese de doutorado apresentada à Faculdade de Engenharia Elétrica e de Computação da Universidade Estadual de Campinas como parte dos requisitos exigidos para a obtenção do título de Doutor em Engenharia Elétrica, na área de Telecomunicações e Telemática.

Orientador: Prof. Dr. Leonardo de Souza Mendes

Coorientador: Prof. Dr. Everton Gomedes

Este trabalho corresponde à versão final da Tese de Doutorado defendida por Luiz Carlos Pinheiro Junior, e orientada pelo Prof. Dr. Leonardo de Souza Mendes.

Campinas

2025

Ficha catalográfica  
Universidade Estadual de Campinas (UNICAMP)  
Biblioteca da Área de Engenharia e Arquitetura  
Rose Meire da Silva - CRB 8/5974

P655a Pinheiro Junior, Luiz Carlos, 1983-  
Algoritmos de emparelhamento estável para otimização de geração de pares em jogos educacionais e outros cenários / Luiz Carlos Pinheiro Junior.  
- Campinas, SP : [s.n.], 2025.

Orientador: Leonardo de Souza Mendes.  
Coorientador: Everton Gomedede.  
Tese (doutorado) – Universidade Estadual de Campinas (UNICAMP),  
Faculdade de Engenharia Elétrica e de Computação.

1. Aprendizado colaborativo. 2. Jogos educativos. I. Mendes, Leonardo de Souza, 1961-. II. Gomedede, Everton, 1979-. III. Universidade Estadual de Campinas (UNICAMP). Faculdade de Engenharia Elétrica e de Computação. IV. Título.

Informações complementares

**Título em outro idioma:** Stable pairing algorithms for optimizing pair generation in educational games and other scenarios

**Palavras-chave em inglês:**

Collaborative learning

Educational games

**Área de concentração:** Telecomunicações e Telemática

**Titulação:** Doutor em Engenharia Elétrica

**Banca examinadora:**

Everton Gomedede [Coorientador]

André Macedo Panhan

Felipe Marques Pires

Gean Davis Breda

Rodolfo Miranda de Barros

**Data de defesa:** 14-03-2025

**Programa de Pós-Graduação:** Engenharia Elétrica

**Objetivos de Desenvolvimento Sustentável (ODS)**

ODS: 4. Educação de qualidade

**Identificação e informações acadêmicas do(a) aluno(a)**

- ORCID do autor: <https://orcid.org/0009-0001-0680-7599>

- Currículo Lattes do autor: <https://lattes.cnpq.br/0173804012532406>

Prof. Dr. Everton Gomedes (Presidente)

Prof. Dr. André Macedo Panhan

Prof. Dr. Felipe Marques Pires

Prof. Dr. Gean Davis Breda

Prof. Dr. Rodolfo Miranda de Barros

A ata de defesa, com as respectivas assinaturas dos membros da Comissão Julgadora, encontra-se no SIGA (Sistema de Fluxo de Dissertação/Tese) e na Secretaria de Pós-Graduação da Faculdade de Engenharia Elétrica e de Computação.

# Dedicatória

Dedico esta tese, primeiramente, à minha família, pelo apoio incondicional, amor e compreensão em todos os momentos desta jornada.

À Márcia, por estar ao meu lado nos desafios e nas conquistas, me incentivando a seguir em frente mesmo nos momentos de dúvida.

Aos meus orientadores e colegas de pesquisa, que me guiaram e inspiraram ao longo desse caminho, oferecendo conhecimento e apoio.

E, finalmente, dedico este trabalho a todos que acreditam na ciência e no poder transformador da educação.

# Agradecimentos

Este trabalho só foi possível graças ao apoio de várias pessoas e instituições, as quais eu gostaria de expressar minha profunda gratidão.

Agradeço, em primeiro lugar, aos meus orientadores, Leonardo de Souza Mendes e Everton Gomedes, pela orientação, paciência e ensinamentos ao longo de toda a minha pesquisa. Seus conselhos foram fundamentais para a conclusão deste trabalho.

À minha família, que sempre esteve ao meu lado, oferecendo suporte emocional e acreditando em meu potencial, mesmo nos momentos mais difíceis.

Aos meus amigos e colegas de pesquisa, pela parceria, troca de ideias e momentos de descontração que tornaram essa jornada mais leve.

Aos professores e profissionais com os quais tive a oportunidade de aprender ao longo da minha formação, minha mais sincera gratidão. Cada contribuição foi essencial para o desenvolvimento deste trabalho.

Agradeço também à Universidade Estadual de Campinas (UNICAMP) por me proporcionar uma formação sólida e de excelência durante o doutorado. As oportunidades e o conhecimento adquirido nesta instituição foram essenciais para a realização deste trabalho e para meu desenvolvimento como pesquisador e ao Instituto Federal do Paraná (IFPR) por conceder o afastamento necessário para que eu pudesse me dedicar a esta pesquisa, o que foi essencial para a realização deste trabalho.

Também sou grato à agência de fomento CNPq pelo apoio financeiro.

A todos, o meu mais sincero agradecimento.

O presente trabalho foi realizado com apoio do CNPq, Conselho Nacional de Desenvolvimento Científico e Tecnológico – Brasil (166114/2018-9).

# Resumo

Esta tese apresenta uma modificação do algoritmo de Gale-Shapley, originalmente desenvolvido para o Stable Marriage Problem (SMP), aplicando-o ao contexto educacional com o objetivo de otimizar a formação de pares em atividades colaborativas e competitivas. O foco é melhorar o desempenho acadêmico e o desenvolvimento de competências socioemocionais dos estudantes em ambientes de aprendizagem suportados por jogos educacionais. A versão modificada do algoritmo foi adaptada para gerar pares com uma única lista de participantes e substitui as preferências tradicionais por métricas de similaridade, como o coeficiente de Jaccard, a distância euclidiana inversa e a similaridade do cosseno, permitindo a formação de pares estáveis e compatíveis de acordo com as características acadêmicas e sociais dos alunos. Este trabalho avaliou a eficácia da versão modificada do algoritmo por meio de simulações computacionais e experimentos em ambientes educacionais reais por meio de jogos digitais educacionais, comparando os resultados com aqueles obtidos por pares formados de maneira aleatória. Os resultados indicaram que o algoritmo modificado promove um maior equilíbrio no desempenho dos estudantes, melhorando tanto a colaboração quanto a competição em atividades educacionais. Observou-se também um impacto positivo no engajamento e na motivação dos alunos, evidenciando que a personalização das correspondências por meio do algoritmo contribui significativamente para a eficácia dos jogos educacionais. Essa abordagem demonstra o potencial do algoritmo modificado para otimizar a aprendizagem personalizada, ao mesmo tempo em que reforça a estabilidade das correspondências e melhora a satisfação dos estudantes em contextos colaborativos e competitivos.

**Palavras Chave:** Gale-Shapley, aprendizagem colaborativa, aprendizagem competitiva, jogos educacionais, emparelhamento estável.

# Abstract

This thesis presents a modification of the Gale-Shapley algorithm, initially developed for the Stable Marriage Problem (SMP), applying it to the educational context to optimize pair formation in collaborative and competitive activities. The focus is on improving academic performance and developing students' socio-emotional skills in learning environments supported by educational games. The modified version of the algorithm replaces traditional preferences with similarity metrics such as Jaccard's coefficient, inverse Euclidean distance, and cosine similarity, allowing for the formation of stable and compatible pairs according to the student's academic and social characteristics. This work evaluated the effectiveness of the modified version of the algorithm using computer simulations and experiments in real educational environments, comparing the results with those obtained by randomly formed pairs. The results indicated that the modified algorithm promotes a better student performance balance, improving collaboration and competition in educational activities. A positive impact on student engagement and motivation was also observed, showing that the personalization of matches by the algorithm contributes significantly to the effectiveness of educational games. This innovative approach demonstrates the potential of the modified SMP to optimize personalized learning while reinforcing the stability of matches and improving student satisfaction in collaborative and competitive contexts.

**Key Word:** Gale-Shapley, collaborative learning, competitive learning, educational games, stable matching.

# Lista de Ilustrações

Figura 1 - Gráfico do tempo de execução da pontuação de compatibilidade (dados numéricos). Fonte: Pinheiro Junior (2024).....	67
Figura 2 - Gráfico que mostra o tempo necessário para calcular a pontuação de compatibilidade (dados numéricos e categóricos). Fonte: Pinheiro Junior (2024).....	68
Figura 3 - Mapa de calor das pontuações de compatibilidade euclidiana inversa.....	69
Figura 4 - Mapa de calor das pontuações de compatibilidade de similaridade de Jaccard.....	70
Figura 5 - Mapa de calor das pontuações de similaridade de cosseno.....	71
Figura 6 - Gráfico das distribuições de emparelhamento utilizando as pontuações de compatibilidade euclidiana inversa no conjunto de dados numéricos. Fonte: Pinheiro Junior (2024).....	72
Figura 7 - Gráfico das distribuições de emparelhamento utilizando as pontuações de compatibilidade Jaccard no conjunto de dados numéricos. Fonte: Pinheiro Junior (2024).....	74
Figura 8 - Gráfico de distribuições de emparelhamento utilizando as pontuações de compatibilidade de cosseno no conjunto de dados numéricos. Fonte: Pinheiro Junior (2024)....	75
Figura 9 - Gráfico das distribuições de emparelhamento utilizando pontuações de compatibilidade euclidiana inversa em conjuntos de dados numéricos e categóricos. Fonte: Pinheiro Junior (2024).....	78
Figura 10 - Gráfico das distribuições de emparelhamento utilizando as pontuações de compatibilidade Jaccard em conjuntos de dados numéricos e categóricos.....	80
Figura 11 - Gráfico de distribuições de emparelhamento utilizando pontuações de compatibilidade Cosseno em conjuntos de dados numéricos e categóricos.....	82
Figura 12 - Comparação do tempo de execução na formação de pares para as métricas de compatibilidade euclidiana inversa, Jaccard e cosseno. Fonte: Pinheiro Junior (2024).....	85
Figura 13 - Comparação de Iterações na Formação de Pares para as Métricas de Compatibilidade Euclidiana Inversa, Jaccard e Cosseno. Fonte: Pinheiro Junior (2024).....	86
Figura 14 - Gráfico de Comparação das pontuações de compatibilidade após a otimização	

com a original. Fonte: Pinheiro Junior (2024).....	88
Figura 15 - Mapa de calor da compatibilidade entre alunos.....	90
Figura 16 - Comparação das pontuações de compatibilidade.....	91
Figura 17 - Gráfico de caixa comparando as diferenças de pontuação de desempenho no jogo..	92
Figura 18 - Gráfico de violino da comparação das diferenças de pontuação de desempenho no jogo.....	93
Figura 19 - Gráfico de caixa da comparação das pontuações médias de desempenho no jogo....	94
Figura 20 - Gráfico em violino da comparação das médias das pontuações de desempenho no jogo.....	95
Figura 21 - Gráfico de caixa da Comparação do Tempo Médio por Resposta no Jogo.....	96
Figura 22 - Gráfico de violino comparando a diferença no tempo médio por resposta no jogo...	97
Figura 23 - Gráfico do nível de engajamento dos estudantes durante o jogo.....	98
Figura 24 - Gráfico do nível de desafio do jogo.....	99
Figura 25 - Gráfico de motivação dos estudantes.....	100
Figura 26 - Gráfico de avaliação dos estudantes sobre a dinâmica e jogo educativo em termos de melhora do aprendizado.....	101

# Lista de Tabelas

Tabela 1 - Amostra de dados gerados pelo SDV antes da normalização.....	65
Tabela 2 - Amostra de dados após a normalização e a codificação one-hot.....	66
Tabela 3 - Dados de emparelhamento utilizando pontuações de compatibilidade euclidiana inversa em conjuntos de dados numéricos.....	73
Tabela 4 - Dados de emparelhamento utilizando pontuações de compatibilidade de Jaccard em conjuntos de dados numéricos.....	74
Tabela 5 - Dados de emparelhamento utilizando as pontuações de compatibilidade de cosseno no conjunto de dados numéricos. Fonte: Pinheiro Junior (2024).....	76
Tabela 6 - Dados do emparelhamento utilizando as pontuações de compatibilidade euclidiana inversa em conjuntos de dados numéricos e categóricos.....	79
Tabela 7 - Dados de emparelhamento utilizando as pontuações de compatibilidade Jaccard inversa em conjuntos de dados numéricos e categóricos.....	81
Tabela 8 - Dados de emparelhamento utilizando as pontuações de compatibilidade do cosseno inverso em conjuntos de dados numéricos e categóricos.....	83

# Lista de Abreviaturas e Siglas

ACO - Ant Colony Optimization (Algoritmo de Otimização por Colônia de Formigas)

DRL - Deep Reinforcement Learning

GA - Genetic Algorithms (Algoritmos Genéticos)

GSM - algoritmo de Gale-Shapley Modificado

IA - Inteligência Artificial

IQR - Intervalo Interquartil

IoT - Internet of Things (Internet das Coisas)

LGPD - Lei Geral de Proteção de Dados Pessoais

ML - Machine Learning (Aprendizado de Máquina)

NRMP - National Resident Matching Program

PSO - Particle Optimization Algorithm (Algoritmo de Otimização por Partículas)

RA - Realidade Aumentada

SDV - Synthetic Data Vault (Biblioteca de Python)

SEL - Social and Emotional Learning (Aprendizagem Social e Emocional)

SMP - Stable Marriage Problem (Problema do Casamento Estável)

# Sumário

## Capítulo 1

<b>Introdução.....</b>	<b>18</b>
1.1 Justificativa.....	20
1.2 Método Científico.....	20
1.3 Objetivo Geral.....	21
1.3.1 Objetivos Específicos.....	21
1.4 Estrutura da Tese.....	22

## Capítulo 2

<b>Revisão da Literatura.....</b>	<b>23</b>
2.1 O Problema do Casamento Estável (SMP).....	23
2.1.1 Definição e Histórico do SMP e o Algoritmo de Gale-Shapley.....	23
2.1.1.1 Aplicações Práticas e Extensões.....	24
2.1.1.2 Aplicação no Sistema de Escolha Escolar.....	24
2.1.1.3 Contribuições Clássicas e Estudos Teóricos.....	25
2.1.1.4 Modelagem Teórica e Design de Mercados.....	26
2.1.1.5 O Prêmio Nobel e o Reconhecimento Internacional.....	26
2.1.1.6 Reinterpretação do Modelo de Gale-Shapley.....	26
2.1.2 Casos de Estudo em Diferentes Setores.....	27
2.1.3 SMP e Inteligência Artificial.....	29
2.1.3.1 Aprendizado de Máquina no SMP.....	29
2.1.3.2 Aprendizado por Reforço no SMP.....	30
2.1.3.3 Algoritmos Genéticos no SMP.....	31
2.1.3.4 Inteligência de Enxame no SMP.....	31

2.1.3.5 Outras Abordagens Inovadoras.....	32
2.1.4 SMP em Cidades Inteligentes.....	33
2.1.5 SMP em Contextos Educacionais.....	34
2.1.5.1 Personalização da Aprendizagem e o Papel dos Algoritmos de Emparelhamento.....	34
2.1.5.2 Exemplos Recentes de Estudos Utilizando Algoritmos em Contextos Educacionais.....	35
2.2 Aprendizagem Social e Emocional (SEL).....	36
2.2.1 Conceitos e Importância da Aprendizagem Social e Emocional.....	36
2.2.2 Efeitos da SEL no Desempenho Acadêmico e Comportamental.....	36
2.2.3 SEL e o Desenvolvimento de Competências Socioemocionais.....	37
2.2.4 Integração da SEL no Ambiente Educacional: Aprendizagem Colaborativa e Competitiva.....	37
2.2.5 O Papel das Tecnologias Educacionais na SEL.....	38
2.3 Jogos Educacionais e Aprendizagem Colaborativa/Competitiva.....	39
2.3.1 Conceitos e Teorias Sobre Jogos Educacionais.....	39
2.3.2 Integração de Métodos Colaborativos e Competitivos em Jogos Educacionais..	41
2.3.3 Aplicações do SMP em Contextos Educacionais.....	42
2.3.4 Teorias de Aprendizagem Colaborativa e Jogos.....	42
2.3.5 Jogos Digitais Competitivos no Desenvolvimento de Habilidades e Motivação dos Alunos.....	44
2.3.6 A Zona de Desenvolvimento Proximal (ZDP) de Vygotsky e a Aprendizagem Colaborativa.....	45
2.3.7 Piaget e a Aprendizagem Ativa por meio da Exploração em Jogos Multiplayer	46
2.3.8 Jogos para Multijogadores e a Mediação Social para a Aprendizagem.....	47
2.3.9 Gamificação e a Personalização do Ensino com Base nas Teorias de Vygotsky e Piaget.....	47

### Capítulo 3

<b>Metodologia.....</b>	<b>49</b>
3.1 Cálculo das Pontuações de Compatibilidade.....	51
3.1.1 Distância Euclidiana Inversa.....	51
3.1.2 Similaridade de Jaccard.....	52
3.1.3 Similaridade de Cosseno.....	52
3.2 Modificação do Algoritmo de Gale-Shapley.....	53
3.2.1 Descrição da Modificação.....	53
3.2.2 Vantagens da Modificação.....	54
3.2.3 Execução do Algoritmo Modificado.....	56
3.2.4 Diferenças em Relação a Trabalhos Anteriores.....	57
3.2.5 Desempenho e Escalabilidade.....	58
3.3 Simulação e Avaliação.....	58
3.3.1 Geração e Normalização de Dados Sintéticos.....	59
3.3.2 Cálculo das Pontuações de Compatibilidade.....	59
3.3.3 Implementação e Execução das Simulações.....	60
3.4 Teste com Jogos Educacionais.....	61
3.4.1 Ambiente do Jogo Digital.....	61
3.4.2 Formação dos Grupos.....	62
3.4.3 Coleta de Dados.....	62
3.4.4 Anonimização dos dados.....	63

## **Capítulo 4**

<b>Resultados e Análise.....</b>	<b>64</b>
4.1 Simulação em SEL.....	64
4.1.1 Geração de Dados.....	64
4.1.2 Cálculo das pontuações de compatibilidade (métrica de compatibilidade).....	66
4.1.3 Avaliação de métricas de compatibilidade em algoritmos de emparelhamento com dados numéricos.....	72
4.1.4 Avaliação das métricas de compatibilidade: Inclusão de dados categóricos e	

numéricos.....	78
4.1.5 Análise de emparelhamento: Variação do número de indivíduos.....	84
4.1.6 Otimização de Pares com Pares como Parâmetros e Avaliação da Eficiência do Algoritmo de Gale-Shapley Modificado.....	87
4.2 Resultados da Aplicação em Jogos Educacionais Competitivos.....	89
4.2.1 Formação de pares.....	89
4.2.2 Comparação de desempenho.....	92
4.2.3 Análise qualitativa do feedback dos alunos.....	97
4.2.3.1 Nível de engajamento.....	98
4.2.3.2 Percepção da aprendizagem.....	98
4.2.3.3 Dificuldade do jogo.....	99
4.2.3.4 Motivação para resolver os desafios.....	100
4.2.3.5 Contribuição do formato para a aprendizagem.....	100
4.2.3.6 Avaliação da Dinâmica e do Jogo Educativo.....	101
4.2.4 Interpretação dos resultados.....	102

## Capítulo 5

<b>Discussão.....</b>	<b>103</b>
5.1 Interpretação dos Resultados da Simulação SEL.....	103
5.2 Interpretação dos Resultados da Aplicação em Jogos Digitais Educacionais Competitivos.....	104
5.2.1 Implicações para a competitividade e o envolvimento.....	104
5.2.2 Satisfação e motivação dos participantes.....	105
5.2.3 Recomendações práticas.....	105
5.2.3.1 Implementação de algoritmos de emparelhamento.....	105
5.2.3.2 Utilização de jogos didáticos.....	106
5.2.3.3 Design de jogos personalizados.....	106
5.2.3.4 Feedback e ajuste da dificuldade.....	107

## Capítulo 6

<b>Conclusão.....</b>	<b>108</b>
6.1 Síntese dos Resultados.....	108
6.2 Limitações.....	109
6.3 Trabalhos Futuros.....	110
6.4 Considerações Finais.....	111
<b>Publicações.....</b>	<b>112</b>
Optimizing Social and Emotional Learning through Modified Gale-Shapley Algorithm for Collaborative and Competitive Education.....	112
Implementation of Stable Pairing Algorithms for Optimizing Educational Games: A Computational and Pedagogical Perspective.....	113
<b>Referências.....</b>	<b>114</b>
APÊNDICE A – Formulário de Avaliação.....	120

# Capítulo 1

## Introdução

Nos últimos anos, o desenvolvimento de algoritmos de emparelhamento estável tem despertado grande interesse em diversas áreas, incluindo economia, educação e ciência da computação (Fenoaltea et al., 2021). Entre os algoritmos mais amplamente estudados está o algoritmo de Gale-Shapley, introduzido por David Gale e Lloyd Shapley em 1962, que aborda o Problema do Casamento Estável (*Stable Marriage Problem* - SMP), um problema clássico da teoria dos jogos e dos algoritmos combinatórios (Gale; Shapley, 1962). O objetivo do SMP é encontrar uma correspondência estável entre dois conjuntos disjuntos de participantes, uma correspondência é considerada estável se não houver dois participantes que prefeririam estar emparelhados entre si em vez de estarem com os parceiros designados pela correspondência (Gale; Shapley, 1962).

Devido à sua capacidade de modelar problemas de correspondência onde a estabilidade é essencial, o SMP tem sido amplamente aplicado em diversas áreas. Exemplos de aplicação incluem o mercado de trabalho (Thiruvady et al., 2021), a alocação de estudantes em escolas (Abdulkadiroğlu; Sönmez, 2003) e a distribuição de órgãos para transplantes (Roth; Sönmez; Ünver, 2004). A importância do SMP é evidente pela sua capacidade de resolver problemas de pareamento em mercados bilaterais, onde a estabilidade das correspondências é necessária para garantir a satisfação das partes envolvidas (Gusfield; Irving, 1989).

No campo da educação, a utilização do algoritmo de Gale-Shapley tem mostrado grande potencial para aprimorar a aprendizagem colaborativa e competitiva, dois métodos centrais para o desenvolvimento cognitivo e socioemocional dos alunos (Pinheiro Junior et al., 2024a). A aprendizagem colaborativa é reconhecida por seu impacto positivo no engajamento e na motivação dos estudantes, enquanto a aprendizagem competitiva contribui para o desenvolvimento de habilidades individuais e promove a superação pessoal (Prince, 2004). Quando equilibrados, ambos os métodos contribuem significativamente para o sucesso

acadêmico e pessoal dos estudantes. Nesse contexto, a formação de pares estáveis e compatíveis desempenha um papel fundamental na eficácia dessas abordagens.

Contudo, as complexas dinâmicas das salas de aula, associadas à heterogeneidade dos perfis estudantis, impõem desafios à aplicação direta do algoritmo de Gale-Shapley em contextos educacionais (Pinheiro Junior et al., 2024a). O GS foi originalmente concebido para resolver o problema do casamento estável, em que dois grupos distintos de participantes, com preferências mútuas, são pareados de forma a garantir a estabilidade do sistema. No entanto, esse modelo tradicional encontra limitações quando aplicado em ambientes educacionais, onde todos os indivíduos pertencem a um único grupo de estudantes. Nesse cenário, a necessidade de adaptação surge devido à ausência de listas de preferências predefinidas e à demanda por uma abordagem mais flexível e eficiente.

Este trabalho propõe uma modificação do algoritmo de Gale-Shapley, adaptada para lidar com um único conjunto de participantes. Essa versão utiliza métricas de similaridade, como o coeficiente de Jaccard, a distância euclidiana inversa e a similaridade do cosseno, para calcular a compatibilidade entre os alunos, substituindo as preferências subjetivas por critérios objetivos. Assim, o algoritmo é capaz de formar pares que não apenas maximizam o desempenho acadêmico, mas também promovem interações sociais produtivas e otimizam o desenvolvimento socioemocional dos estudantes, alinhando-se aos objetivos das intervenções de Aprendizagem Social e Emocional (Pinheiro Junior et al., 2024a). Além disso, esta abordagem visa garantir a formação de pares estáveis e eficazes, potencializando o impacto dessas intervenções em termos de habilidades interpessoais e acadêmicas.

Diante disso, as hipóteses testadas neste estudo são as seguintes: A **hipótese nula (H0)** postula que não há diferença significativa entre o desempenho e a interação social dos estudantes emparelhados com base no algoritmo modificado em comparação com pares formados aleatoriamente. Por outro lado, a **hipótese alternativa (H1)** sugere que a aplicação do algoritmo modificado, com métricas de compatibilidade, resulta em melhorias significativas no desempenho acadêmico e nas interações sociais dos estudantes, em relação aos métodos tradicionais de pareamento aleatório.

## 1.1 Justificativa

A justificativa para o desenvolvimento e aplicação de um algoritmo modificado de emparelhamento estável no contexto educacional fundamenta-se em dois aspectos principais: (1) a necessidade de **otimizar o desempenho acadêmico dos estudantes** e (2) a importância de **promover o desenvolvimento de competências socioemocionais**, que são cruciais para o sucesso a longo prazo. A aprendizagem colaborativa, caracterizada pela interação entre pares, tem demonstrado aumentar significativamente a motivação dos estudantes, enquanto a aprendizagem competitiva pode auxiliar no desenvolvimento de habilidades críticas, proporcionando um ambiente de rivalidade saudável. Quando equilibradas, ambas as abordagens promovem um ambiente de aprendizagem dinâmico e interativo, justificando assim a adaptação do algoritmo de Gale-Shapley ao contexto educacional.

Métodos tradicionais de ensino frequentemente não conseguem engajar os alunos de forma eficaz. A introdução de jogos educacionais, em conjunto com a correspondência estável proporcionada pelo algoritmo modificado de Gale-Shapley, pode não apenas aumentar a motivação dos alunos, mas também simular situações práticas e realistas, facilitando a compreensão de conceitos complexos. A aplicação do algoritmo em jogos educacionais busca a formação de pares estáveis e compatíveis, aumentando a eficácia da aprendizagem e promovendo um ambiente interativo. Nesse ambiente, colaboração e competição ocorrendo de maneira equilibrada, tende a otimizar o desenvolvimento acadêmico e socioemocional dos estudantes.

## 1.2 Método Científico

Neste estudo, a modificação do algoritmo de Gale-Shapley foi projetada para operar em um contexto educacional com uma única lista de estudantes. O algoritmo original, que pressupõe dois grupos distintos de participantes, foi ajustado para considerar apenas um conjunto de indivíduos, formando pares com base em métricas objetivas de similaridade. As métricas utilizadas incluem:

- **Similaridade de Jaccard:** avalia a interseção entre conjuntos de competências ou desempenhos acadêmicos;

- **Distância Euclidiana Inversa:** mede a proximidade entre os perfis acadêmicos dos estudantes, destacando aqueles com trajetórias mais próximas;
- **Similaridade do Cosseno:** avalia a semelhança entre vetores de características, ignorando a magnitude, e foca na direção das habilidades e competências dos estudantes, permitindo o emparelhamento de alunos com perfis semelhantes.

A utilização dessas métricas permite a formação de pares que otimizam tanto o desempenho acadêmico quanto promovem interações sociais e emocionais produtivas, alinhadas ao desenvolvimento colaborativo e competitivo. Esse modelo ajustado para funcionar com apenas uma lista de indivíduos e com cálculo de compatibilidade se alinha com as necessidades educacionais contemporâneas ao equilibrar a formação de pares estáveis e a eficiência computacional do algoritmo.

## 1.3 Objetivo Geral

O objetivo geral desta tese é avaliar a eficácia da aplicação do **algoritmo modificado de Gale-Shapley** em **ambientes educacionais**, com foco na **formação de pares estáveis** e compatíveis em atividades **colaborativas** e **competitivas**. A aplicação desse algoritmo tem potencial para melhorar tanto o desempenho acadêmico quanto as interações sociais entre os estudantes, promovendo um ambiente mais engajado, equilibrado e propício ao desenvolvimento de competências socioemocionais.

### 1.3.1 Objetivos Específicos

- Avaliar a eficácia da versão modificada do algoritmo de Gale-Shapley na formação de pares estáveis em ambientes educacionais;
- Comparar o desempenho dos estudantes alocados pelo algoritmo modificado em relação aos pares formados de maneira aleatória;
- Analisar o impacto da formação de pares em atividades educacionais colaborativas e competitivas;
- Explorar a aplicação do algoritmo em jogos educacionais e analisar seu efeito sobre o engajamento e a motivação dos estudantes.

## 1.4 Estrutura da Tese

A tese está organizada em seis capítulos, sendo esse o Capítulo 1, que apresenta a introdução ao tema, justificativa, objetivos e estrutura do trabalho. O restante da tese está estruturada da seguinte forma:

- **Capítulo 2: Revisão de Literatura** - Apresenta uma revisão da literatura sobre o SMP e suas aplicações, com foco principal em aplicações educacionais. Além de uma revisão sobre aprendizagem social e emocional e jogos educacionais.
- **Capítulo 3: Metodologia** - Descreve a abordagem metodológica utilizada na pesquisa, detalhando o desenvolvimento da modificação do algoritmo e a forma de teste e aplicação.
- **Capítulo 4: Resultados** - Apresenta os resultados obtidos com as aplicações do SMP.
- **Capítulo 5: Discussão** - Discute os resultados, suas implicações teóricas e práticas, e as limitações do estudo.
- **Capítulo 6: Conclusão** - Resume os principais achados da pesquisa, oferece recomendações para futuras aplicações e considerações finais.

# Capítulo 2

## Revisão da Literatura

### 2.1 O Problema do Casamento Estável (SMP)

#### 2.1.1 Definição e Histórico do SMP e o Algoritmo de Gale-Shapley

O Problema do Casamento Estável (SMP) foi introduzido em 1962 por David Gale e Lloyd Shapley no artigo "*College Admissions and the Stability of Marriage*" (Gale; Shapley, 1962), onde os autores formalizaram um problema clássico em alocação sob preferências. Esse problema envolve dois grupos, com o objetivo de encontrar um emparelhamento estável. Um emparelhamento é considerado estável quando não existe nenhum par de indivíduos que prefira estar um com o outro em detrimento dos parceiros que lhe foram atribuídos. Para resolver essa questão, Gale e Shapley propuseram o Algoritmo de Aceitação Diferida, também conhecido por algoritmo Gale-Shapley, que garante a estabilidade dos emparelhamentos ao final do processo.

O Algoritmo de Gale-Shapley funciona por meio de um procedimento iterativo no qual um dos grupos faz propostas ao outro grupo, que podem aceitar provisoriamente uma proposta e rejeitar outras, mantendo a melhor proposta recebida até o momento. O processo continua até que todos os indivíduos estejam emparelhados de forma estável, garantindo que não haja pares instáveis. Esse algoritmo sempre resulta em uma solução estável, independentemente das preferências iniciais (Gale; Shapley, 1962).

### **2.1.1.1 Aplicações Práticas e Extensões**

O SMP encontrou uma de suas principais aplicações no mercado de trabalho médico dos Estados Unidos, especificamente no emparelhamento de médicos residentes com programas de residência médica. O *National Resident Matching Program* (NRMP), responsável por alocar médicos recém-formados a programas de residência, enfrentava problemas de instabilidade antes de sua reformulação. Alvin Roth, em seu trabalho de 1984, demonstrou que o algoritmo de Gale-Shapley poderia ser adaptado para esse contexto, resultando em alocações estáveis e eficientes (Roth, 1984).

Posteriormente, Roth e Peranson (1999) aperfeiçoaram esse trabalho ao redesenhar o NRMP, levando em consideração as preferências tanto dos médicos quanto dos programas de residência. Esse novo sistema resultou em uma solução que eliminou as instabilidades observadas anteriormente, consolidando o algoritmo de Gale-Shapley como uma ferramenta prática para resolver problemas reais de alocação em mercados de dois lados (Roth; Peranson, 1999).

Outra aplicação importante do SMP foi no campo das trocas de órgãos. Roth, Sönmez e Ünver (2004) adaptaram o modelo de casamento estável para resolver problemas de troca de rins entre doadores vivos e receptores. Ao utilizar o algoritmo de Gale-Shapley, foi possível aumentar a eficiência do sistema de trocas, permitindo a realização de transplantes em situações onde doadores não eram diretamente compatíveis com os receptores designados (Roth; Sönmez; Ünver, 2004).

### **2.1.1.2 Aplicação no Sistema de Escolha Escolar**

O SMP também provou ser útil no campo da escolha escolar, especialmente em sistemas públicos de alocação de vagas escolares. Em 2003, Abdulkadiroğlu e Sönmez propuseram a aplicação do algoritmo de Gale-Shapley para resolver problemas de alocação em escolas públicas. O uso desse mecanismo garantiu que o processo de alocação fosse justo e eficiente, levando em conta as preferências tanto dos alunos quanto das escolas, e evitando emparelhamentos indesejados ou instáveis (Abdulkadiroğlu; Sönmez, 2003).

Mais tarde, no sistema de ensino médio de Nova York, Abdulkadiroğlu, Pathak e Roth (2009) redesenharam o sistema de alocação escolar com base no algoritmo de casamento estável. Eles enfrentaram o desafio das indiferenças nas preferências, um fenômeno comum em mercados reais, onde alunos ou escolas não possuem preferências estritas. O algoritmo foi ajustado para lidar com essas situações, garantindo a estabilidade e eficiência da alocação (Abdulkadiroğlu; Pathak; Roth, 2009).

### 2.1.1.3 Contribuições Clássicas e Estudos Teóricos

Além de suas aplicações práticas, o SMP foi amplamente estudado no campo teórico. Um dos primeiros estudiosos a abordar o problema após Gale e Shapley foi Donald Knuth, em seu livro "*Mariages Stables*" (1976). Knuth analisou o problema do casamento estável sob uma perspectiva algorítmica e computacional, aprofundando-se nas propriedades matemáticas e complexidade computacional do algoritmo de Gale-Shapley (Knuth, 1976).

Outra contribuição importante veio de Lester Dubins e David Freedman, no artigo "*Machiavelli and the Gale-Shapley Algorithm*" (1981). Esses autores exploraram as propriedades estratégicas do algoritmo, mostrando como o grupo que faz as propostas obtém uma vantagem ao conseguir o melhor emparelhamento possível dentro de suas preferências (Dubins; Freedman, 1981).

O estudo sobre o SMP também foi expandido por Robert W. Irving, que abordou o problema de indiferença nas preferências em seu artigo "*Stable Marriage and Indifference*" (1994). Irving desenvolveu algoritmos capazes de lidar com a ausência de preferências estritas, um problema comum em mercados reais, como escolha de escolas e emparelhamentos médicos (Irving, 1994).

Por fim, o livro de David F. Manlove, "*Algorithmics of Matching Under Preferences*" (2013), oferece uma análise abrangente sobre o SMP e suas variantes, com foco na complexidade algorítmica e nas diversas formas de emparelhamentos estáveis em diferentes cenários (Manlove, 2013).

#### **2.1.1.4 Modelagem Teórica e *Design* de Mercados**

Outro estudo fundamental para o desenvolvimento da teoria do casamento estável foi realizado por Roth e Sotomayor (1990). No livro "*Two-Sided Matching: A Study in Game-Theoretic Modeling and Analysis*", os autores investigam as dinâmicas estratégicas em mercados bilaterais, onde ambos os lados (como alunos e escolas, ou médicos e hospitais) possuem preferências. Esse trabalho foi pioneiro na conexão entre a teoria dos jogos cooperativos e o SMP, analisando como as soluções estáveis se relacionam com o equilíbrio de Nash e oferecendo *insights* sobre o comportamento estratégico dos agentes (Roth; Sotomayor, 1990).

#### **2.1.1.5 O Prêmio Nobel e o Reconhecimento Internacional**

O SMP e o Algoritmo de Gale-Shapley ganharam reconhecimento internacional quando Lloyd Shapley e Alvin Roth foram agraciados com o Prêmio Nobel de Economia em 2012. Shapley foi reconhecido por sua coautoria no desenvolvimento do algoritmo, enquanto Roth foi premiado por suas contribuições à aplicação prática da teoria de emparelhamento estável em mercados reais, como o NRMP e o sistema de trocas de órgãos. Esse prêmio consagrou a importância da teoria de emparelhamentos estáveis para o *design* de mercados bilaterais e a teoria dos jogos.

#### **2.1.1.6 Reinterpretação do Modelo de Gale-Shapley**

Uma nova interpretação do modelo original de Gale-Shapley foi proposta por Fenoaltea et al. (2021), destacando as implicações da assimetria de informação entre os participantes. Nesta variação, os proponentes têm mais informações sobre as preferências do grupo oposto, enquanto os recipientes possuem informações limitadas. Esse cenário simula situações da vida real em que uma das partes tem mais dados para basear suas escolhas, enquanto a outra parte adota uma postura passiva devido à falta de informações. Nesse modelo, os recipientes recebem propostas e mantêm temporariamente a melhor oferta que receberam, sem possuir uma lista de preferências pré-definida. Se receberem novas propostas, têm a oportunidade de avaliar e escolher a melhor oferta disponível, funcionando de maneira semelhante ao modelo

clássico, mas com uma diferença: a decisão de aceitar ou rejeitar não é baseada em uma classificação fixa, mas na avaliação contínua das opções disponíveis.

A interpretação de Fenoaltea et al. (2021) oferece uma explicação para a postura passiva dos recipientes no modelo original, sugerindo que a falta de informações os impede de fazer ofertas. Além disso, os autores destacam que, em cenários reais, essa deficiência informacional pode ser prejudicial e impactar negativamente o resultado final da correspondência. Aqueles que possuem mais informações e tomam decisões ativas tendem a obter resultados melhores do que aqueles que dependem de escolhas passivas. Esse estudo reforça a importância da disponibilidade de informações e da proatividade na formação de correspondências estáveis e eficientes, tanto no contexto do SMP quanto em suas aplicações no mundo real.

### **2.1.2 Casos de Estudo em Diferentes Setores**

Diversos estudos de caso destacam a eficácia do SMP em contextos práticos variados, demonstrando seu impacto positivo em termos de eficiência, justiça e satisfação dos participantes.

Um caso de sucesso amplamente estudado é o NRMP, que utiliza uma versão modificada do algoritmo de Gale-Shapley para alocar médicos residentes em hospitais. Essa aplicação é elogiada pela sua capacidade de garantir que a maioria dos participantes, tanto os residentes quanto os programas de residência, fiquem satisfeitos com suas correspondências. Além disso, o NRMP ajuda a minimizar o tempo de espera para alocações e maximiza a eficiência do processo, resultando em uma solução amplamente estável e equitativa (Roth, 1984).

Outro estudo de caso importante é o sistema de alocação escolar da cidade de Nova Iorque. A implementação do SMP nesse contexto gerou melhorias substanciais na equidade e na eficiência do processo de distribuição de vagas escolares (Abdulkadiroğlu; Pathak; Roth, 2009). O SMP permitiu que as escolas respeitassem suas restrições de capacidade, enquanto mais alunos foram alocados às suas preferências de escolha de escola, aumentando a satisfação entre alunos e pais. O mesmo efeito foi observado em Boston, onde a adoção do

SMP promoveu uma distribuição mais justa das vagas e a satisfação aumentou em relação ao sistema anterior.

Na área da saúde, o SMP também foi aplicado com sucesso na distribuição de órgãos para transplante. O sistema considera as preferências dos pacientes e a compatibilidade dos órgãos, resultando em alocações mais justas e otimizadas. Essa abordagem não só reduz o tempo de espera dos pacientes, mas também melhora os resultados dos transplantes ao garantir que os órgãos sejam alocados de maneira eficiente e que beneficiem mais os receptores em potencial (Roth et al., 2005). Esse uso do SMP tem um impacto direto na redução da mortalidade e na melhoria da qualidade de vida dos pacientes, destacando a relevância social e a eficácia prática do SMP em resolver problemas críticos.

Além das áreas tradicionais, o SMP tem mostrado versatilidade ao ser aplicado em cidades inteligentes e em Internet das Coisas (*Internet of Things* - IoT), onde sistemas de recomendação e alocação de recursos são otimizados com base nas preferências dos usuários. Lei et al. (2020) propuseram o uso do SMP em sistemas de mobilidade urbana, onde a correspondência estável entre usuários e serviços de transporte otimiza a distribuição de vagas em estacionamentos, veículos compartilhados e rotas de transporte público. Nesse contexto, o SMP ajuda a maximizar a satisfação dos usuários enquanto melhora a eficiência do sistema como um todo.

Outros exemplos incluem a alocação de estudantes a dormitórios universitários (Chang & Lin, 2021; Fidan & Erdem, 2021) e a colocação de trabalhadores na indústria (Thiruvady et al., 2021). O SMP foi também aplicado em áreas emergentes como veículos aéreos não tripulados (*drones*) para alocar recursos de forma eficiente, em redes sem fio para a distribuição de largura de banda, e até em plataformas de *crowdsourcing*, onde o SMP garante a alocação justa de tarefas entre trabalhadores disponíveis (Huang et al., 2023). Em cada uma dessas aplicações, o SMP provou ser uma ferramenta robusta para garantir estabilidade, eficiência e justiça.

Estudos recentes também destacam o uso do SMP na comunidade *online* de saúde mental, onde voluntários conselheiros são emparelhados com indivíduos que procuram apoio emocional. Nesse contexto, o SMP assegura que os voluntários sejam alocados de forma eficiente e compatível com as necessidades dos indivíduos, melhorando a qualidade do suporte oferecido (Y. Liu et al., 2023).

Esses estudos de caso evidenciam a versatilidade do SMP como uma ferramenta de otimização, capaz de resolver uma ampla gama de problemas de correspondência em diferentes setores. Em cada aplicação, o uso do SMP resultou em melhorias significativas na eficiência dos processos, na satisfação dos participantes e na justiça das alocações, demonstrando o impacto positivo e o potencial de expansão do SMP em contextos variados.

### 2.1.3 SMP e Inteligência Artificial

O SMP tradicionalmente resolvido por meio de algoritmos como o de Gale-Shapley, tem se beneficiado de avanços em Inteligência Artificial (IA) para lidar com a crescente complexidade e dinamismo dos cenários modernos. Em particular, técnicas de aprendizado de máquina (*Machine Learning* - ML), aprendizado profundo, aprendizado por reforço, e algoritmos genéticos têm sido integradas para otimizar processos de emparelhamento, permitindo que o SMP seja aplicado em contextos mais amplos, como mercados dinâmicos, redes sociais, e plataformas de serviços digitais.

#### 2.1.3.1 Aprendizado de Máquina no SMP

Técnicas de ML são particularmente úteis para processar grandes volumes de dados, identificando padrões nas preferências dos agentes e prevendo os melhores emparelhamentos possíveis. Em ambientes dinâmicos, onde as preferências dos participantes mudam ao longo do tempo, o uso de redes neurais e modelos preditivos possibilita que os sistemas se adaptem de forma eficiente, ajustando as correspondências com base nos comportamentos passados e nas tendências emergentes (Gafni; Cohen, 2022). O aprendizado de máquina pode ser utilizado para otimizar a correspondência inicial, ajustar preferências com base em novas informações e reavaliar os emparelhamentos à medida que novos dados são recebidos.

- **Redes neurais profundas:** Essas redes são particularmente eficazes em cenários de *big data*, onde grandes conjuntos de preferências são processados para encontrar correspondências ótimas. Redes neurais profundas são capazes de aprender padrões complexos de preferências e ajustar as correspondências de maneira iterativa, melhorando continuamente a estabilidade e a satisfação dos participantes (Mlika; Cherkaoui, 2022).

- **Aprendizado supervisionado e não supervisionado:** No caso do SMP, o aprendizado supervisionado pode ser utilizado quando existem dados históricos sobre correspondências bem-sucedidas, permitindo que o algoritmo aprenda com as preferências anteriores. O aprendizado não supervisionado, por outro lado, é útil quando as preferências são desconhecidas ou incertas, agrupando agentes com base em características semelhantes e gerando correspondências estáveis sem a necessidade de informações completas (Chen et al., 2022).

### 2.1.3.2 Aprendizado por Reforço no SMP

O aprendizado por reforço tem emergido como uma técnica poderosa para lidar com o SMP em ambientes dinâmicos, onde as preferências dos agentes evoluem ao longo do tempo. Nesse contexto, os agentes são modelados como jogadores que interagem com o ambiente e recebem recompensas com base na qualidade de suas correspondências. O sistema utiliza essas recompensas para ajustar suas estratégias de correspondência, otimizando a satisfação geral.

- **Algoritmos de aprendizado por reforço profundo (*Deep Reinforcement Learning - DRL*):** Essa técnica combina redes neurais profundas com aprendizado por reforço, permitindo que o sistema aprenda a otimizar emparelhamentos em cenários complexos e dinâmicos. O DRL tem sido utilizado para melhorar a resiliência das correspondências em mercados *online*, plataformas de serviços digitais e redes sociais, onde as preferências dos usuários mudam constantemente (Zhao et al., 2023). O algoritmo aprende a maximizar a recompensa de cada correspondência, ajustando-se iterativamente para melhorar a eficiência e estabilidade.

Um exemplo prático dessa abordagem está em plataformas de comércio eletrônico, onde produtos e consumidores são emparelhados com base nas preferências dinâmicas e no comportamento de compra dos usuários. O aprendizado por reforço permite que as plataformas ajustem as recomendações em tempo real, garantindo que tanto os vendedores quanto os compradores estejam satisfeitos com as correspondências (Gafni; Cohen, 2022).

### 2.1.3.3 Algoritmos Genéticos no SMP

Outro avanço na aplicação de IA ao SMP é o uso de algoritmos genéticos (*Genetic Algorithms* - GA). Inspirados pelo processo de seleção natural, os GA são úteis para encontrar soluções ótimas em problemas de emparelhamento ao gerar, combinar e mutar soluções ao longo de várias iterações, semelhantes às gerações na natureza.

- **Seleção natural e otimização de emparelhamentos:** Em vez de buscar a solução ideal de forma direta, os algoritmos genéticos geram várias soluções possíveis para o SMP e as testam em diferentes condições, selecionando as melhores com base em critérios como estabilidade e satisfação dos agentes (Eyupoglu et al., 2021). Com o tempo, essas soluções evoluem, aproximando-se da correspondência ideal. Esse processo é eficaz para encontrar soluções quando os agentes possuem preferências complexas ou contraditórias.
- **Hibridização com redes neurais:** Em alguns estudos, os algoritmos genéticos são combinados com redes neurais para gerar correspondências ainda mais eficientes. As redes neurais aprendem as preferências iniciais dos agentes, enquanto os GAs trabalham para otimizar essas correspondências ao longo do tempo, ajustando as soluções conforme as preferências evoluem (Mlika; Cherkaoui, 2022).

### 2.1.3.4 Inteligência de Enxame no SMP

Algoritmos de inteligência de enxame, como o Algoritmo de Otimização por Colônia de Formigas (*Ant Colony Optimization* - ACO) e o Algoritmo de Otimização por Partículas (*Particle Optimization Algorithm* - PSO), também têm sido utilizados para resolver o SMP em cenários de múltiplos agentes. Esses algoritmos simulam o comportamento coletivo de sistemas biológicos, como formigas em busca de alimentos ou partículas buscando a solução ótima em um espaço de busca, para encontrar correspondências estáveis em ambientes dinâmicos.

- **Algoritmo de Otimização por Colônia de Formigas (ACO):** A adaptação do ACO ao SMP envolve a simulação do comportamento de formigas na busca por soluções ótimas de emparelhamento. Cada formiga (agente) faz propostas e ajusta seu comportamento com base nas soluções encontradas por outras formigas. Isso cria um

processo de *feedback* colaborativo que melhora continuamente a qualidade dos emparelhamentos (Thiruvady et al., 2021).

- **Otimização por Partículas (PSO):** No PSO, cada partícula representa uma solução possível para o SMP. As partículas exploram o espaço de soluções em busca de correspondências estáveis e, ao longo do tempo, ajustam suas posições com base nas experiências das outras partículas. Essa abordagem tem sido particularmente útil em cenários de múltiplos agentes, onde as preferências são desconhecidas ou podem mudar ao longo do tempo (Viet et al., 2019).

### 2.1.3.5 Outras Abordagens Inovadoras

Além das técnicas já mencionadas, outras abordagens de IA, como programação lógica declarativa, algoritmos quânticos, e algoritmos de busca local bidirecional, têm sido exploradas para resolver o SMP. Esses métodos oferecem novas maneiras de lidar com as complexidades do problema de emparelhamento, especialmente em ambientes onde os recursos são limitados e as preferências dos agentes são dinâmicas ou incertas.

- **Algoritmos quânticos:** O uso de algoritmos quânticos para o SMP está em fase inicial de desenvolvimento, mas já demonstrou um grande potencial para acelerar a busca por correspondências ótimas, especialmente em cenários com um grande número de agentes. A capacidade dos computadores quânticos de processar múltiplas soluções simultaneamente pode reduzir drasticamente o tempo necessário para resolver o SMP em grande escala (Fidan; Erdem, 2021).
- **Busca local bidirecional:** Esse algoritmo trabalha explorando o espaço de soluções de duas direções simultâneas, melhorando a eficiência da busca por correspondências estáveis. A busca local bidirecional permite que o sistema encontre soluções de forma mais rápida e eficiente em cenários onde as preferências dos agentes são complexas ou incertas (Shafigh et al., 2023).

### 2.1.4 SMP em Cidades Inteligentes

Nos últimos anos, a versatilidade do SMP tem sido explorada em novos campos além das aplicações tradicionais, como educação, saúde e mercados de trabalho. Cidades inteligentes emergem como contextos relevantes para a aplicação do SMP, dado o crescente interesse em otimizar recursos e melhorar a eficiência em ambientes urbanos e digitais complexos.

O conceito de cidades inteligentes abrange o uso de tecnologias avançadas e sistemas integrados para melhorar a eficiência dos serviços urbanos, desde transporte até a alocação de recursos como energia e água. Em um ambiente urbano dinâmico, onde múltiplos agentes (como usuários de transporte, prestadores de serviços e gestores urbanos) possuem diferentes preferências e restrições, a aplicação do SMP oferece soluções que garantem a alocação estável e otimizada dos recursos.

Um estudo de Lei et al. (2020) investigou o uso do SMP em sistemas de recomendação de atividades em cidades inteligentes. Nesse contexto, os residentes de uma cidade e os provedores de serviços são modelados como dois grupos de agentes com preferências. O SMP é utilizado para alocar atividades ou serviços, como vagas de estacionamento, transporte compartilhado ou mesmo eventos culturais, de forma que a satisfação dos cidadãos seja maximizada, garantindo a estabilidade das correspondências. Além disso, o uso do SMP neste cenário possibilita que as preferências evoluam com base em dados coletados em tempo real sobre as necessidades e comportamentos dos cidadãos, permitindo que o sistema se adapte continuamente às mudanças nas preferências urbanas.

A implementação do SMP em cidades inteligentes é particularmente relevante para a mobilidade urbana. Fortino et al. (2020) propuseram a aplicação do algoritmo de Gale-Shapley para resolver problemas de alocação de vagas em sistemas de *carsharing* e *ridesharing*. O desafio nesses sistemas envolve equilibrar a oferta e a demanda de veículos em tempo real, levando em conta as preferências dos passageiros e a disponibilidade dos veículos. Ao utilizar o SMP, é possível garantir que os passageiros sejam alocados a veículos de forma que a estabilidade seja mantida, ou seja, que nenhum passageiro e motorista prefira trocar de parceiro.

Esses exemplos demonstram como o SMP pode ser uma ferramenta poderosa na organização de sistemas complexos em cidades inteligentes, onde há múltiplas partes

interessadas e recursos limitados. A capacidade de garantir estabilidade em um sistema urbano dinâmico é essencial para maximizar a eficiência dos serviços e aumentar a satisfação dos usuários.

### **2.1.5 SMP em Contextos Educacionais**

A aplicação de algoritmos em ambientes educacionais, especialmente em plataformas de aprendizagem colaborativa, apresenta desafios específicos que precisam ser considerados. Um desses desafios envolve a compatibilidade entre estudantes com diferentes níveis acadêmicos, estilos de aprendizagem e traços socioemocionais. Conforme discutido por Yusri et al. (2021), a incompatibilidade na formação de pares pode prejudicar a dinâmica de grupo e comprometer o processo de aprendizagem. A seleção inadequada de parceiros pode diminuir a motivação e o engajamento, afetando negativamente o desempenho dos alunos.

Outro desafio é lidar com as respostas sociais e emocionais dos estudantes em relação à formação de grupos. As plataformas de aprendizagem colaborativa frequentemente não consideram as dinâmicas interpessoais que surgem de pares com características incompatíveis em termos de personalidade ou preferências colaborativas, o que pode resultar em dificuldades durante as atividades educacionais. Fenoaltea et al. (2021) destacam a necessidade de garantir que não apenas a compatibilidade acadêmica seja considerada, mas também a coesão social, a fim de promover resultados de aprendizagem mais eficazes.

Portanto, a aplicação de algoritmos de emparelhamento em ambientes educacionais precisa levar em consideração fatores socioemocionais, além de aspectos puramente acadêmicos, para otimizar os resultados e evitar frustrações no processo colaborativo.

#### **2.1.5.1 Personalização da Aprendizagem e o Papel dos Algoritmos de Emparelhamento**

A personalização da aprendizagem tem se mostrado um aspecto fundamental para aumentar o engajamento dos estudantes e melhorar os resultados educacionais. Um dos principais problemas enfrentados por plataformas educacionais é como automatizar o processo de formação de pares levando em conta as diferenças individuais nos estilos de aprendizagem, níveis de conhecimento e traços comportamentais. Yusri et al. (2021) propõem o uso de

métricas de similaridade, como o coeficiente de Jaccard e a similaridade do cosseno, para comparar perfis de estudantes tanto em termos acadêmicos quanto comportamentais. Essa abordagem permite formar pares ou grupos com habilidades complementares e estilos de trabalho compatíveis.

A personalização pode ser ampliada pela integração de métricas que também avaliem competências sociais e emocionais, principalmente em atividades que envolvem competição ou colaboração. Girard et al. (2021) demonstram que *frameworks* que consideram essas características geram melhores resultados, uma vez que os pares formados são compatíveis não apenas em termos de conhecimento, mas também na capacidade de trabalhar de forma eficiente em conjunto.

Assim, ao adotar uma abordagem mais personalizada para a formação de pares, as plataformas educacionais podem não apenas melhorar o desempenho acadêmico, mas também criar um ambiente de aprendizagem mais colaborativo e engajador.

#### **2.1.5.2 Exemplos Recentes de Estudos Utilizando Algoritmos em Contextos Educacionais**

Estudos recentes aplicaram o algoritmo de Gale-Shapley em contextos educacionais com resultados promissores. Yusri et al. (2021), por exemplo, investigaram uma plataforma de *e-learning* voltada para a educação em privacidade, na qual o algoritmo de emparelhamento foi utilizado para selecionar pares de estudantes em atividades colaborativas. Esse estudo é especialmente relevante para o seu trabalho, pois combina fatores acadêmicos e comportamentais para formar correspondências estáveis, o que resultou em maior engajamento dos alunos e melhores resultados de aprendizagem.

Outro estudo importante é o de Girard et al. (2021), que adaptou um algoritmo semelhante para agrupar estudantes de acordo com suas necessidades educacionais em um programa de educação sobre privacidade. Esse modelo de correspondência não apenas aumentou a satisfação dos estudantes, mas também melhorou significativamente o desempenho acadêmico quando comparado a grupos formados de maneira aleatória.

Além disso, Lei et al. (2020) aplicaram o algoritmo em ambientes de cidades inteligentes, otimizando a alocação de recursos em sistemas de transporte. Embora esse

estudo se concentre em um contexto diferente, os princípios subjacentes de correspondência estável em ambientes dinâmicos e de alocação de recursos limitados são diretamente aplicáveis à gestão de pares em contextos educacionais, onde o desempenho e a motivação dos estudantes podem variar consideravelmente.

## **2.2 Aprendizagem Social e Emocional (SEL)**

### **2.2.1 Conceitos e Importância da Aprendizagem Social e Emocional**

A Aprendizagem Social e Emocional (*Social and Emotional Learning* - SEL) refere-se ao processo pelo qual os alunos desenvolvem habilidades essenciais para o reconhecimento e gestão das próprias emoções, o estabelecimento de relacionamentos saudáveis, a tomada de decisões responsáveis e a resolução eficaz de conflitos. Essas competências são fundamentais não apenas para o sucesso acadêmico, mas também para a formação de indivíduos bem ajustados emocionalmente e capazes de lidar com os desafios da vida cotidiana e do trabalho em sociedade (Durlak et al., 2011).

A importância da SEL tem sido amplamente documentada por estudos que mostram seus impactos positivos no desenvolvimento global dos estudantes. Esses estudos apontam que programas de SEL implementados no ambiente escolar contribuem significativamente para o aumento do desempenho acadêmico, a redução de problemas comportamentais, a melhoria da saúde mental e a promoção de comportamentos pró-sociais (Cipriano et al., 2023). A aprendizagem socioemocional é, portanto, um componente essencial da educação contemporânea, que visa a formação integral do aluno, indo além do ensino tradicional de conteúdos curriculares.

### **2.2.2 Efeitos da SEL no Desempenho Acadêmico e Comportamental**

Programas baseados em SEL demonstram efeitos de longo prazo no desenvolvimento acadêmico e pessoal dos alunos. Pesquisas revelam que a implementação de intervenções sistemáticas de SEL melhora significativamente o desempenho acadêmico, as competências sociais e a capacidade de adaptação dos estudantes ao longo da vida (Zins; Elias, 2007). Além

disso, essas intervenções promovem uma regulação emocional mais eficaz, empatia e comportamentos colaborativos, todos essenciais para o sucesso em ambientes cada vez mais colaborativos e interconectados.

De acordo com Durlak et al. (2011), uma meta-análise de intervenções de SEL indicou que os alunos que participam desses programas apresentam melhoras consideráveis em suas notas escolares, ao mesmo tempo que apresentam uma redução nos níveis de ansiedade e agressão. Esses resultados sugerem que, ao investir no desenvolvimento emocional e social dos alunos, as escolas não apenas promovem um ambiente mais saudável, mas também ajudam a construir uma base sólida para o aprendizado acadêmico.

### **2.2.3 SEL e o Desenvolvimento de Competências Socioemocionais**

A SEL promove o desenvolvimento de cinco competências-chave que são críticas para o bem-estar e o sucesso acadêmico dos alunos: autoconsciência, autogerenciamento, consciência social, habilidades de relacionamento e tomada de decisões responsável (Durlak et al., 2011). Estas competências ajudam os alunos a compreender e gerenciar suas emoções, estabelecer e manter relacionamentos positivos, e tomar decisões baseadas em valores éticos e de responsabilidade social.

Essas habilidades socioemocionais são fundamentais para preparar os alunos para os desafios do século XXI, onde as exigências do mercado de trabalho e a complexidade social requerem habilidades interpessoais e intrapessoais avançadas (Cipriano et al., 2023). O desenvolvimento de tais competências possibilita aos alunos trabalhar eficazmente em equipes, liderar com empatia e adaptar-se rapidamente a novas situações.

### **2.2.4 Integração da SEL no Ambiente Educacional: Aprendizagem Colaborativa e Competitiva**

A integração da SEL com métodos de aprendizagem colaborativa e competitiva oferece uma abordagem eficaz para a promoção de habilidades socioemocionais no ambiente escolar. A aprendizagem colaborativa, por exemplo, envolve os alunos trabalhando juntos para alcançar

objetivos comuns, incentivando a interdependência positiva e a cooperação. Ao trabalhar em equipe, os alunos aprendem a ouvir, respeitar e colaborar uns com os outros, o que fortalece suas habilidades de comunicação e resolução de conflitos (Johnson; Johnson, 2014).

Por outro lado, a aprendizagem competitiva incentiva os alunos a melhorar seu desempenho individual, promovendo a resiliência e a capacidade de se superar diante de desafios. No entanto, a competição deve ser equilibrada com a colaboração para garantir que todos os alunos tenham a oportunidade de desenvolver tanto habilidades individuais quanto sociais. Estudos mostram que ambientes que combinam aspectos colaborativos e competitivos são mais eficazes para o desenvolvimento de competências socioemocionais e acadêmicas (Gokhale, 1995).

### **2.2.5 O Papel das Tecnologias Educacionais na SEL**

A tecnologia desempenha um papel crescente na facilitação da SEL, especialmente por meio de plataformas digitais que integram a aprendizagem adaptativa e personalizada. Ferramentas como a Realidade Aumentada (RA), por exemplo, oferecem experiências interativas e imersivas que podem ser usadas para promover a colaboração entre os alunos, ao mesmo tempo em que personalizam o processo de aprendizagem com base nas necessidades individuais (Saif; Mahayuddin; Shapi'i, 2021). Essas tecnologias ajudam a engajar os alunos de forma mais dinâmica, permitindo que eles experimentem e pratiquem habilidades socioemocionais em cenários virtuais realistas.

Além disso, jogos educativos digitais têm se mostrado ferramentas eficazes para promover a SEL, oferecendo um ambiente seguro onde os alunos podem praticar competências como a tomada de decisões responsável e a empatia (Huang, 2019). Esses jogos podem ser projetados para incluir desafios colaborativos e competitivos, criando oportunidades para os alunos desenvolverem habilidades de comunicação e cooperação, enquanto praticam a regulação emocional e o pensamento crítico.

A integração da SEL no ambiente educacional é fundamental para o desenvolvimento integral dos alunos, preparando-os para os desafios acadêmicos e sociais do século XXI. Ao promover competências socioemocionais por meio de métodos colaborativos e competitivos, as escolas podem criar um ambiente de aprendizado mais saudável e eficaz, onde os alunos se

sentem capacitados a enfrentar os desafios de maneira resiliente e empática. Além disso, o uso de tecnologias educacionais, como a RA e os jogos digitais, pode potencializar a SEL, proporcionando experiências interativas e personalizadas que maximizam o aprendizado socioemocional dos alunos.

## **2.3 Jogos Educacionais e Aprendizagem Colaborativa/Competitiva**

### **2.3.1 Conceitos e Teorias Sobre Jogos Educacionais**

Jogos educacionais são ferramentas pedagógicas que utilizam dinâmicas de jogo para engajar estudantes e facilitar a aprendizagem. Estes jogos podem ser tanto colaborativos quanto competitivos, oferecendo um ambiente interativo onde os alunos podem aplicar conhecimentos de forma prática (Gee, 2003). Estudos mostram que jogos educacionais podem aumentar a motivação e o envolvimento dos alunos, levando a uma aprendizagem mais eficaz (Prince, 2004).

A literatura sobre jogos educacionais destaca a importância de integrar elementos de competição e colaboração para maximizar os resultados de aprendizagem. Segundo Gee (2003), jogos que incorporam desafios competitivos podem estimular o pensamento crítico e a resolução de problemas. Em contraste, jogos colaborativos promovem habilidades sociais e de trabalho em equipe, essenciais para o desenvolvimento acadêmico e profissional dos alunos (Johnson; Johnson, 1999).

Os jogos educacionais tornaram-se ferramentas fundamentais no campo da educação contemporânea, proporcionando uma maneira eficaz de engajar os alunos, promover o aprendizado ativo e desenvolver habilidades socioemocionais. No entanto, é importante distinguir entre três abordagens principais: jogos colaborativos, jogos competitivos e gamificação, cada uma com características e aplicações específicas que atendem a diferentes necessidades pedagógicas.

**Jogos Colaborativos:** Esses jogos são projetados para incentivar os alunos a trabalhar em conjunto para atingir um objetivo comum. Eles enfatizam a importância do trabalho em equipe, cooperação e resolução coletiva de problemas, onde o sucesso depende da contribuição de todos os participantes. No campo educacional, jogos colaborativos podem ser aplicados em disciplinas como ciências, onde os alunos são incentivados a resolver problemas complexos em grupo, como simulações de laboratório ou jogos que envolvem a gestão de recursos naturais em cenários ambientais (Vygotsky, 1978; Johnson; Johnson, 1999). Um exemplo prático é o jogo “Minecraft: Education Edition”<sup>1</sup>, utilizado para promover a colaboração entre alunos no planejamento e execução de projetos de construção baseados em conceitos científicos.

**Jogos Competitivos:** Em contraste, jogos competitivos envolvem os alunos em desafios onde o objetivo é superar os colegas. Esses jogos são eficazes para estimular a motivação intrínseca, desenvolvendo habilidades de resolução rápida de problemas e promovendo um senso de realização individual. A competição pode ser aplicada em disciplinas como matemática, onde alunos competem para resolver problemas complexos mais rapidamente. Um exemplo é o “Kahoot!”<sup>2</sup>, uma plataforma de testes interativos que promove a competição em tempo real, estimulando o pensamento crítico e rápido (Deci; Ryan, 1985; Prince, 2004). É importante, no entanto, que os jogos competitivos sejam cuidadosamente equilibrados para evitar o estresse ou desmotivação, incentivando uma competição saudável e construtiva.

**Gamificação:** A gamificação é uma abordagem diferente, onde elementos típicos dos jogos, como pontuações, níveis e recompensas, são integrados em contextos educacionais para aumentar o engajamento dos alunos. Diferente dos jogos puramente colaborativos ou competitivos, a gamificação pode ser aplicada a qualquer disciplina, tornando o aprendizado mais dinâmico e envolvente, sem que a atividade em si seja necessariamente um jogo. Um exemplo é o uso de sistemas de pontos e recompensas em plataformas de aprendizado adaptativo, como o “Duolingo”<sup>3</sup>, para motivar o aprendizado contínuo de línguas (Hamari et al., 2014; Prensky, 2001).

---

<sup>1</sup> <https://education.minecraft.net/>

<sup>2</sup> <https://kahoot.com/>

<sup>3</sup> <https://pt.duolingo.com/>

Essas três abordagens oferecem oportunidades valiosas para personalizar e diversificar o processo de ensino, atendendo a diferentes estilos de aprendizagem e objetivos pedagógicos. A pesquisa de Prensky (2001) sugere que a combinação de elementos colaborativos e competitivos nos jogos pode criar um ambiente de aprendizagem mais equilibrado e eficaz, onde tanto as habilidades cognitivas quanto as sociais são desenvolvidas.

### **2.3.2 Integração de Métodos Colaborativos e Competitivos em Jogos Educacionais**

A aprendizagem colaborativa envolve alunos trabalhando juntos para alcançar um objetivo comum, promovendo habilidades sociais e cognitivas (Johnson; Johnson, 1999). Em contraste, a aprendizagem competitiva coloca os alunos em situações onde eles competem uns contra os outros, o que pode estimular a melhoria de desempenho por meio do desafio e da motivação (Deci; Ryan, 1985). Ambos os métodos podem ser integrados em jogos educacionais para maximizar os benefícios pedagógicos.

Estudos indicam que a integração de métodos colaborativos e competitivos em jogos educacionais pode resultar em uma aprendizagem mais equilibrada e abrangente. A pesquisa de Prince (2004) revela que alunos expostos a ambientes de aprendizagem que combinam colaboração e competição apresentam melhor desempenho acadêmico e maior satisfação com o processo de aprendizagem.

Os estudos indicam que a integração de métodos colaborativos e competitivos em jogos educacionais pode resultar em uma aprendizagem mais abrangente e equilibrada. A pesquisa de Prince (2004) demonstra que os alunos que experimentam ambos os métodos de aprendizagem tendem a apresentar um desempenho acadêmico superior e uma maior satisfação no processo educacional. Isso ocorre porque a colaboração fomenta o apoio entre pares e o compartilhamento de conhecimentos, enquanto a competição estimula o desenvolvimento de habilidades individuais e a motivação intrínseca para superar desafios.

### 2.3.3 Aplicações do SMP em Contextos Educacionais

A aplicação do SMP em jogos educacionais pode facilitar a formação de grupos de trabalho estáveis, onde as preferências dos alunos são consideradas para maximizar a satisfação e a produtividade do grupo (Kim; Lee, 2018). Jogos que utilizam o SMP para criar correspondências podem promover uma aprendizagem colaborativa e competitiva eficaz, ao mesmo tempo que ensinam aos alunos conceitos importantes sobre estabilidade e otimização (Lee; Kang, 2016).

Na prática, o uso do SMP em contextos educacionais tem mostrado resultados promissores. Por exemplo, Kim e Lee (2018) destacam que jogos baseados em SMP podem melhorar a dinâmica de grupo e aumentar a participação dos alunos em atividades colaborativas. Além disso, jogos que simulam cenários de correspondência estável ajudam os alunos a compreenderem melhor conceitos matemáticos e algoritmos, preparando-os para desafios acadêmicos futuros (Lee; Kang, 2016).

### 2.3.4 Teorias de Aprendizagem Colaborativa e Jogos

Integrar teorias de aprendizagem colaborativa com jogos educacionais para multijogadores representa uma estratégia avançada na educação moderna, combinando princípios pedagógicos com aspectos envolventes da tecnologia. A aprendizagem colaborativa é valorizada por melhorar a aquisição de conhecimento e fomentar habilidades sociais essenciais. Esta abordagem enfatiza a resolução coletiva de problemas e a exploração conceitual, facilitadas pelo suporte e interação entre pares no processo educacional. O conceito da Zona de Desenvolvimento Proximal (ZDP) destaca o papel vital das interações sociais na aprendizagem, indicando o potencial das atividades colaborativas para impulsionar o desenvolvimento cognitivo dentro dessa zona (Piaget, 1969; Vygotsky, 1978; Slavin, 1996; Johnson; Johnson, 1999).

A proliferação da tecnologia, especialmente por meio de jogos educacionais e plataformas *online*, avançou o modelo de aprendizagem interativa e colaborativa. Essas ferramentas eliminam barreiras geográficas tradicionais, introduzindo métodos inovadores de comunicação e colaboração, enriquecendo assim a experiência educacional (Resta; Laferrière, 2007; Kirschner; Erkens, 2013). Jogos digitais são particularmente notáveis por oferecer

experiências interativas únicas, promovendo o engajamento ativo com o conteúdo educacional e permitindo a exploração de diversas identidades e perspectivas, melhorando assim o processo educacional (Prensky, 2001; Gee, 2007).

O *design* de jogos educacionais requer foco na criatividade, aprendizagem ativa, alinhamento com objetivos educacionais e fornecimento de desafios equilibrados, metas claras e *feedback* imediato. Este método de *design* equipa os alunos com habilidades para enfrentar desafios da vida real (Kafai, 2006; Tekinbas; Zimmerman, 2003; Mcgonigal, 2011). A incorporação da cultura participativa e da narrativa transmídia também é recomendada para aumentar as qualidades imersivas e interativas desses jogos (Jenkins, 2006).

Jogos educacionais para multijogadores melhoram o trabalho em equipe e a comunicação dos alunos, promovendo interações construtivas e tomada de decisões coletiva. Esses jogos são fundamentais para o desenvolvimento de habilidades sociais e emocionais no contexto educacional (Connolly et al., 2012; Gambrell, 2011). O papel do *feedback* e da reflexão na aprendizagem é enfatizado, com jogos para multijogadores atuando como ferramentas de avaliação formativa, permitindo que os alunos refinem estratégias e aprofundem sua compreensão do conteúdo (Hattie, 2008).

A importância das estratégias de aprendizagem colaborativa para o sucesso educacional é sublinhada, com a interdependência positiva e a responsabilidade individual sendo fundamentais para o *design* de jogos educacionais para multijogadores envolventes (Cohen; Lotan, 2014). Além disso, na era digital, desenvolver habilidades de pensamento crítico e letramento midiático é uma necessidade, com jogos para multijogadores proporcionando um ambiente para aprimorar essas habilidades. (Hobbs, 2011).

O *framework* teórico da autodeterminação, destacando a importância da autonomia, competência e relação na aprendizagem, alinha-se com a taxonomia motivacional para explicar o engajamento em jogos. Esses elementos, embutidos nas dinâmicas de jogo, contribuem para um ambiente motivacional onde os alunos estão ansiosos para aprender e encontram alegria e satisfação (Ryan et al., 2006). Os aspectos culturais e imersivos dos jogos, discutidos por Johan Huizinga (2016) e Csikszentmihalyi (1990), respectivamente, ressaltam as ricas e envolventes experiências de aprendizagem que os jogos educacionais para multijogadores podem oferecer, superando métodos educacionais tradicionais.

Criar oportunidades colaborativas em jogos educacionais é fundamental para as teorias de aprendizagem colaborativa, melhorando o engajamento profundo e sustentado. Atividades que incentivam o trabalho em equipe em direção a objetivos comuns fortalecem a coesão do grupo e o desenvolvimento de habilidades sociais e introduzem um jogo dinâmico de tensão e cooperação, essencial para a experiência de aprendizagem. Facilitar a comunicação e a interação dos jogadores em ambientes virtuais e reais reforça a abordagem colaborativa, promovendo uma jornada de aprendizagem compartilhada que valoriza as contribuições individuais dentro de um *framework* coletivo (Laine; Lindberg, 2020).

### **2.3.5 Jogos Digitais Competitivos no Desenvolvimento de Habilidades e Motivação dos Alunos**

Jogos digitais em ambientes educacionais introduzem um ambiente competitivo que pode melhorar significativamente as habilidades críticas dos alunos. A integração adequada da competição, quando equilibrada com objetivos educacionais, é um forte motivador, estimulando a participação ativa e cultivando um senso de realização e progresso. A chave é alinhar os aspectos competitivos do *design* do jogo com as metas de aprendizagem, garantindo que o impulso competitivo complementa, em vez de ofuscar, a intenção educacional, mantendo o foco dos alunos nos resultados da aprendizagem (Vlachopoulos; Makri, 2017).

Evidências sugerem que a competição em jogos educacionais pode aumentar a motivação e o engajamento dos alunos, especialmente em disciplinas com baixo interesse. A introdução de elementos lúdicos e competitivos em ambientes de aprendizagem aumentou o envolvimento e a motivação dos alunos, apoiando a noção de que a gamificação pode encorajar efetivamente o engajamento ativo (Hamari et al., 2014).

Estabelecer uma atmosfera competitiva construtiva para maximizar os benefícios educacionais, ao mesmo tempo em que mitiga o potencial de estresse ou efeitos negativos. Uma abordagem integrada que combine elementos competitivos e colaborativos pode promover um ambiente de aprendizagem equilibrado e inclusivo, onde os alunos se sintam valorizados e motivados a participar (Buckley; Doyle, 2014).

A personalização e o aprendizado adaptativo são primordiais em jogos educacionais competitivos, ajustando os desafios para corresponder às habilidades individuais dos alunos. Oferecer desafios em níveis adequados é essencial para manter os alunos engajados, proporcionando um nível de desafio mais equilibrado, mantendo o engajamento e facilitando a aquisição contínua de conhecimento e aprendizado mais profundo (Conati; Kardan, 2013; Domínguez et al., 2013).

Jogos digitais competitivos devem incorporar elementos que promovam o desenvolvimento de habilidades e motivem os alunos. Utilizando a competição como uma ferramenta motivacional, os educadores podem projetar jogos que desafiem os jogadores contra outros, contra si mesmos ou contra o sistema do jogo, criando um ambiente educacional dinâmico e estimulante. A competição pode ser projetada de forma síncrona, com os jogadores competindo em tempo real, ou assíncrona, utilizando mecanismos como *rankings* para registrar conquistas. A competição estruturada melhora a motivação ao reconhecer a competência e a conquista, enquanto desafios competitivos em grupo que combinam competição e colaboração podem melhorar a experiência de aprendizagem, promovendo o desenvolvimento de habilidades sociais e cognitivas essenciais (Laine; Lindberg, 2020).

Jogos educacionais digitais que incorporam elementos competitivos oferecem uma estratégia robusta para aprimorar as experiências educacionais, permitindo o desenvolvimento de habilidades cognitivas, sociais e emocionais. Ao equilibrar cuidadosamente os elementos competitivos com os objetivos educacionais e criar um ambiente de suporte, os educadores podem aproveitar esses jogos como ferramentas eficazes para engajar e motivar os alunos, promovendo assim resultados de aprendizagem significativos e duradouros.

### **2.3.6 A Zona de Desenvolvimento Proximal (ZDP) de Vygotsky e a Aprendizagem Colaborativa**

A teoria de Vygotsky é central para entender como os jogos para multijogadores podem facilitar a aprendizagem colaborativa. O conceito de Zona de Desenvolvimento Proximal (ZDP) de Vygotsky refere-se à distância entre o que um aluno pode realizar de forma independente e o que ele pode alcançar com a ajuda de um colega mais experiente ou de um

adulto. A ZDP destaca a importância da interação social para o desenvolvimento cognitivo, uma vez que a aprendizagem ocorre por meio da colaboração com outros, em um ambiente que oferece apoio adequado para que o aluno atinja novos níveis de entendimento e competência (Vygotsky, 1978).

Nos jogos multiplayer, o design pode ser estruturado de modo a criar oportunidades para que alunos com diferentes níveis de habilidade colaborem, com os mais avançados auxiliando os que estão em fases anteriores de desenvolvimento. Essa estrutura promove um ambiente onde a ZDP é constantemente explorada, pois os alunos mais experientes podem servir como mediadores para os menos experientes, ajudando-os a resolver problemas complexos ou a alcançar objetivos dentro do jogo. Por exemplo, em um jogo como "World of Warcraft"<sup>4</sup>, os jogadores frequentemente colaboram em missões que exigem diferentes níveis de habilidade e estratégia, e os jogadores mais experientes acabam orientando e ensinando os novatos, o que exemplifica como a ZDP pode ser explorada em ambientes de jogos digitais.

### **2.3.7 Piaget e a Aprendizagem Ativa por meio da Exploração em Jogos Multiplayer**

A teoria de Jean Piaget também oferece *insights* importantes sobre como os jogos podem facilitar o aprendizado ativo e a exploração. Para Piaget, a aprendizagem ocorre por meio de processos de assimilação e acomodação, nos quais os alunos internalizam novas informações e ajustam seus esquemas cognitivos em resposta a experiências do mundo ao seu redor (Piaget, 1969). Jogos multiplayer, por sua natureza interativa, criam um ambiente rico em aprendizagem ativa, onde os jogadores são constantemente desafiados a ajustar suas estratégias e a desenvolver novas habilidades para progredir no jogo.

No contexto de jogos multiplayer, a exploração colaborativa se torna um componente importante. Jogos como "Minecraft: Education Edition", por exemplo, permitem que os alunos explorem ambientes abertos e complexos, construam soluções e resolvam problemas em conjunto. O *design* desses jogos incentiva a criação de hipóteses, a experimentação e a correção de erros, permitindo que os jogadores reflitam sobre suas ações e ajustem suas estratégias de acordo com as novas informações que obtêm durante o processo. Esse tipo de

---

<sup>4</sup> <https://worldofwarcraft.blizzard.com/>

jogo ativa o processo de equilibração de Piaget, onde os alunos estão constantemente equilibrando as novas experiências com seus conhecimentos pré-existentes.

### **2.3.8 Jogos para Multijogadores e a Mediação Social para a Aprendizagem**

A combinação das teorias de Vygotsky e Piaget sugere que o *design* de jogos para multijogadores deve focar na criação de oportunidades para que os alunos não apenas interajam uns com os outros, mas também assumam papéis de facilitadores ou aprendizes, dependendo de seu nível de habilidade. A presença de *feedback* imediato dentro dos jogos também é uma ferramenta poderosa que pode ser alinhada com o conceito de reflexão proposto por Piaget e com a ideia de mediação de Vygotsky.

Os jogos multiplayer, como “League of Legends”<sup>5</sup>, por exemplo, podem ser projetados para oferecer *feedback* constante e direcionado aos jogadores, orientando suas decisões e promovendo o ajuste contínuo de suas táticas. Isso não apenas promove uma aprendizagem mais dinâmica e contínua, como também incentiva o desenvolvimento de habilidades metacognitivas, uma vez que os jogadores são incentivados a refletir sobre suas ações e ajustar seu comportamento com base nos resultados que obtêm.

### **2.3.9 Gamificação e a Personalização do Ensino com Base nas Teorias de Vygotsky e Piaget**

A gamificação pode ser vista como uma aplicação prática dessas teorias, onde o sistema educacional pode ser adaptado para oferecer desafios personalizados que se ajustam à ZDP de cada aluno. No contexto de um jogo educativo, é possível desenvolver um sistema de mentoria onde os alunos mais avançados recebem recompensas por ajudar outros jogadores, criando um ciclo contínuo de *feedback* positivo que reforça tanto o aprendizado colaborativo quanto o competitivo. Assim, a estrutura do jogo pode simular um ambiente onde a ZDP é explorada de forma intencional, incentivando a cooperação ao mesmo tempo em que os alunos são desafiados a superar suas limitações individuais.

---

<sup>5</sup> <https://www.leagueoflegends.com/>

Um exemplo de gamificação é o uso de pontos e *badges* em plataformas de aprendizado como o “Duolingo”, que aplica a teoria de Vygotsky ao incentivar a colaboração por meio de competições amistosas entre pares que possuem diferentes níveis de fluência em idiomas. A progressão dos jogadores é visível em *rankings* públicos, mas há também um incentivo à ajuda mútua, por meio de fóruns e interações que incentivam o compartilhamento de dicas e truques.

# Capítulo 3

## Metodologia

Este capítulo detalha a metodologia empregada nesta pesquisa, que visa avaliar a eficácia de um algoritmo modificado de Gale-Shapley na formação de pares compatíveis entre estudantes no contexto educacional. A escolha desta metodologia se justifica pela necessidade de desenvolver uma abordagem que não apenas otimize a compatibilidade entre os alunos, mas também promova o engajamento e a motivação em ambientes de aprendizagem colaborativa e competitiva. Ao adaptar um algoritmo consagrado para um novo contexto, buscamos contribuir para a área de estudo oferecendo uma solução inovadora para a formação de pares em atividades educacionais.

A metodologia foi estruturada de forma a atender aos seguintes objetivos específicos:

- Avaliar a eficácia da versão modificada do algoritmo de Gale-Shapley na formação de pares estáveis em ambientes educacionais;
- Comparar o desempenho dos estudantes alocados pelo algoritmo modificado em relação aos pares formados de maneira aleatória;
- Analisar o impacto da formação de pares em atividades educacionais colaborativas e competitivas;
- Explorar a aplicação do algoritmo em jogos educacionais e analisar seu efeito sobre o engajamento e a motivação dos estudantes.

Para alcançar esses objetivos, a metodologia compreende as seguintes etapas principais:

1. **Cálculo das Pontuações de Compatibilidade:** Utilizamos medidas de similaridade para calcular as pontuações de compatibilidade entre os estudantes, visando identificar pares que possam colaborar de maneira eficaz. As métricas escolhidas incluem a

distância euclidiana inversa, a similaridade de Jaccard e a similaridade de cosseno, que permitem avaliar diferentes aspectos das características dos alunos.

2. **Modificação do Algoritmo de Gale-Shapley:** Adaptamos o algoritmo original para trabalhar com uma única lista de indivíduos, substituindo as preferências subjetivas por métricas objetivas de compatibilidade. Essa modificação é fundamental para aplicá-lo em contextos educacionais, onde os alunos não expressam preferências explícitas por outros colegas.
3. **Simulação e Avaliação:** Realizamos simulações para testar o algoritmo modificado em diferentes cenários, variando o tamanho dos grupos de estudantes e os tipos de dados utilizados (numéricos e categóricos). Essa etapa visa avaliar a eficiência, a escalabilidade e a eficácia do algoritmo na formação de pares estáveis e compatíveis.
4. **Teste com Jogos Educacionais:** Aplicamos o algoritmo em um ambiente real por meio de um jogo digital educacional chamado "Labirinto da Educação". Neste contexto, comparamos o desempenho e o engajamento dos estudantes alocados pelo algoritmo modificado com aqueles formados aleatoriamente, permitindo analisar o impacto da formação de pares na aprendizagem colaborativa e competitiva.
5. **Coleta e Análise de Dados:** Coletamos dados quantitativos (desempenho no jogo, tempo de resposta, pontuações) e qualitativos (questionários de satisfação e engajamento) para avaliar os efeitos da formação de pares sobre os estudantes. As análises estatísticas e temáticas realizadas fornecem insights sobre a eficácia do algoritmo e seu impacto educacional.
6. **Garantia do Anonimato e Conformidade Ética:** Implementamos procedimentos rigorosos para garantir o anonimato dos participantes, seguindo as diretrizes da Lei Geral de Proteção de Dados Pessoais (LGPD) e as normas éticas da pesquisa acadêmica.

Ao adotar essa metodologia, buscamos não apenas testar a eficiência técnica do algoritmo modificado, mas também compreender seu potencial impacto educacional, alinhando nossos procedimentos aos objetivos específicos da pesquisa. A combinação de simulações controladas e testes em ambientes reais fornece uma base sólida para avaliar a aplicabilidade e os benefícios do algoritmo no contexto educacional.

## 3.1 Cálculo das Pontuações de Compatibilidade

A primeira etapa da implementação desse sistema envolve o cálculo das pontuações de compatibilidade entre os participantes. A inovação está em modificar esse algoritmo para trabalhar com uma única lista de indivíduos, utilizando métricas como a **distância euclidiana inversa**, a **similaridade de Jaccard** e a **similaridade de cosseno**. Essas métricas ajudam a determinar a proximidade e a similaridade entre os indivíduos, facilitando a criação de pares balanceados em termos de habilidades e estilos de aprendizagem.

### 3.1.1 Distância Euclidiana Inversa

Mede a distância inversa entre dois pontos em um espaço multidimensional e é útil para identificar a proximidade entre as preferências dos alunos. A distância euclidiana mede a distância "real" ou "direta" entre dois pontos em um espaço multidimensional. A fórmula padrão para calcular a distância euclidiana entre dois pontos  $p$  e  $q$  em um espaço  $n$ -dimensional é:

$$d(p, q) = \sqrt{\sum_{i=1}^n (q_i - p_i)^2} \quad (1)$$

Onde  $q_i$  e  $p_i$  são as coordenadas dos pontos  $q$  e  $p$ , respectivamente, e  $n$  é o número de dimensões.

A distância euclidiana inversa, por outro lado, é o inverso dessa medida e é usada para calcular a proximidade ou a similaridade em vez da distância. Ela é expressa como:

$$\text{distância Euclidiana Inversa} = \frac{1}{1+d(p,q)} \quad (2)$$

Essa fórmula garante que, quando a distância euclidiana é pequena (indicando alta similaridade), o valor da distância euclidiana inversa é grande e vice-versa.

### 3.1.2 Similaridade de Jaccard

A similaridade de Jaccard é uma métrica utilizada para avaliar o quanto dois conjuntos são semelhantes, considerando tanto seus elementos em comum quanto os distintos. Ela é calculada dividindo o número de elementos que os conjuntos têm em comum (interseção) pelo número total de elementos presentes em ambos os conjuntos (união). Para dois conjuntos  $A$  e  $B$ , a fórmula é:

$$J(A, B) = \left| \frac{A \cap B}{A \cup B} \right| \quad (3)$$

Onde  $A \cap B$  é o número de elementos em comum entre  $A$  e  $B$ , e  $A \cup B$  é o número total de elementos exclusivos presentes em ambos os conjuntos  $A$  e  $B$ .

### 3.1.3 Similaridade de Cosseno

A similaridade de cosseno mede o cosseno do ângulo entre dois vetores no espaço multidimensional e é usada para calcular a similaridade independentemente da magnitude dos vetores. Para dois vetores  $A$  e  $B$ , a fórmula é:

$$\text{Similaridade de Cosseno} = \frac{A \cdot B}{\|A\| \times \|B\|} \quad (4)$$

Onde  $A \cdot B$  é o produto escalar de vetores  $A$  e  $B$ , e  $\|A\|$  e  $\|B\|$  são as normais (ou magnitudes) dos vetores  $A$  e  $B$ , respectivamente.

A similaridade de cosseno é benéfica em sistemas de recomendação e análise de texto, em que a orientação dos vetores é mais importante do que a magnitude (por exemplo, ao comparar documentos com base na contagem de palavras).

Essas métricas fornecem perspectivas diferentes sobre similaridade ou compatibilidade e são fundamentais para calcular as pontuações de compatibilidade em sistemas de emparelhamento, como o proposto para jogos educacionais.

## 3.2 Modificação do Algoritmo de Gale-Shapley

Com as pontuações de compatibilidade calculadas, o próximo passo consiste em aplicar o algoritmo de emparelhamento modificado. O principal desafio reside na adaptação do algoritmo de Gale-Shapley para operar em um cenário com uma única lista de participantes, em contraste com o formato original que utiliza duas listas de preferências. Esta modificação é fundamental para acomodar a realidade de muitos ambientes educacionais e colaborativos, onde todos os participantes pertencem a um único grupo e as preferências são substituídas por métricas de compatibilidade calculadas.

### 3.2.1 Descrição da Modificação

Na sua formulação clássica, o algoritmo de Gale-Shapley foi concebido para resolver o problema do casamento estável entre dois grupos de indivíduos, cada um com uma lista de preferências explícitas sobre o outro grupo. No entanto, no contexto desta pesquisa, em que temos uma única lista de participantes, o algoritmo foi modificado para trabalhar de forma a maximizar a compatibilidade geral entre os indivíduos, com base em pontuações previamente calculadas a partir de medidas como a distância euclidiana inversa, similaridade de Jaccard e similaridade cosseno.

A adaptação do algoritmo segue os seguintes princípios:

- **Substituição das Preferências:** Em vez de listas de preferências fixas, como no algoritmo original, utilizam-se as pontuações de compatibilidade calculadas entre todos os pares possíveis de participantes. Estas pontuações são ordenadas para cada indivíduo, de forma que os pares com maior compatibilidade sejam priorizados no processo de emparelhamento.
- **Iteração e Formação de Pares:** O algoritmo itera sobre os indivíduos, tentando formar pares que maximizem a compatibilidade. A cada rodada, cada participante “propõe” emparelhamento ao indivíduo com a maior pontuação de compatibilidade disponível. Se o indivíduo já estiver emparelhado, ele aceitará a nova proposta caso o novo proponente tenha uma compatibilidade superior à do par atual.

- **Critério de Parada:** O processo continua até que todos os participantes estejam emparelhados ou que não existam mais propostas possíveis que melhorem a compatibilidade global. Essa abordagem garante que os pares formados sejam equilibrados em termos de compatibilidade, promovendo um ambiente colaborativo mais eficiente, especialmente em contextos educacionais.

A modificação proposta não apenas preserva a essência do algoritmo de Gale-Shapley, mas também aprimora sua aplicabilidade em contextos educacionais, onde a formação de pares deve ser baseada em características objetivas, como habilidades e estilos de aprendizagem, em vez de preferências subjetivas. Essa adaptação assegura que o processo de emparelhamento seja mais dinâmico e flexível, permitindo uma melhor adequação às necessidades individuais dos estudantes e promovendo um ambiente de colaboração mais produtivo. Além disso, a simplificação do processo de pareamento em uma única lista torna o algoritmo mais eficiente e escalável, facilitando sua aplicação em turmas de diferentes tamanhos e contextos educacionais variados.

### 3.2.2 Vantagens da Modificação

A adaptação do algoritmo de Gale-Shapley para uma única lista apresenta várias vantagens em relação ao modelo original, especialmente quando aplicado em contextos educacionais. Para fortalecer as afirmações a seguir, é importante apoiar cada vantagem com referências a estudos ou literatura que sustentem esses pontos.

1. **Compatibilidade Global Otimizada:** Enquanto o modelo clássico busca estabilidade com base em preferências bilaterais, a modificação permite otimizar a compatibilidade geral dos pares formados. Isso se traduz em um melhor equilíbrio entre os participantes, maximizando a eficiência e a satisfação em contextos educacionais. Estudos têm demonstrado que a utilização de métricas objetivas de compatibilidade na formação de pares pode melhorar significativamente a eficácia da aprendizagem colaborativa. Por exemplo, Yusri et al. (2021) exploraram como métricas de similaridade podem levar a correspondências mais eficazes entre estudantes, resultando em um melhor desempenho acadêmico e maior satisfação dos participantes.

2. **Flexibilidade para Ambientes Educacionais:** O uso de uma única lista de participantes torna o modelo mais adequado à realidade de contextos educacionais, nos quais não é comum que os estudantes expressem preferências explícitas por colegas ou parceiros de trabalho. Em vez disso, todos são avaliados com base em um conjunto comum de critérios objetivos — como habilidades, interesses e estilos de aprendizagem. Essa abordagem facilita a formação de pares ou grupos mais equilibrados, especialmente em turmas diversas, onde é necessário conciliar diferentes perfis. Estudos indicam que considerar essas características objetivas na formação de grupos favorece um aprendizado mais eficaz, colaborativo e inclusivo. Girard et al. (2021) destacam a importância de adaptar algoritmos de emparelhamento para contextos educacionais, enfatizando que a consideração de competências e estilos de aprendizagem dos estudantes é crucial para o sucesso das atividades colaborativas.
3. **Simplicidade na Implementação:** A modificação proposta preserva a estrutura essencial do algoritmo original de Gale-Shapley, mantendo sua simplicidade e eficiência computacional. Ao substituir as preferências subjetivas por pontuações objetivas de compatibilidade, o algoritmo permanece leve e funcional, mesmo em contextos de grande escala. Essa característica é especialmente vantajosa em ambientes educacionais, como turmas com dezenas ou centenas de estudantes, onde a formação manual de pares seria inviável. Por exemplo, em uma escola com 200 alunos participando de atividades em dupla, o algoritmo pode gerar combinações equilibradas em segundos, considerando critérios como estilo de aprendizagem, níveis de proficiência ou interesses acadêmicos. Em plataformas de ensino online, essa abordagem pode ser integrada para formar grupos automaticamente ao início de cada módulo, adaptando-se dinamicamente às mudanças no perfil dos estudantes. Estudos sobre algoritmos de emparelhamento destacam que a simplicidade e a escalabilidade são fundamentais para garantir a viabilidade prática dessas soluções. Manlove (2013) enfatiza que algoritmos eficientes são essenciais para formar correspondências rapidamente, sem comprometer a qualidade dos pares — um fator crucial em sistemas educacionais com grandes populações estudantis ou em plataformas digitais com milhares de usuários ativos.

Além dessas vantagens, a modificação também se destaca pela sua adaptabilidade a diferentes contextos educacionais, permitindo ajustes nas métricas de compatibilidade de acordo com as necessidades específicas de cada grupo de estudantes. Isso possibilita a

personalização do processo de emparelhamento, garantindo que o algoritmo seja versátil o suficiente para lidar com a heterogeneidade das turmas e as particularidades de cada disciplina. Estudos destacam que a personalização na formação de pares é essencial para aumentar o engajamento dos alunos e criar um ambiente de aprendizagem mais produtivo.

### 3.2.3 Execução do Algoritmo Modificado

O algoritmo modificado proposto nesta tese tem como principal objetivo formar pares estáveis e altamente compatíveis, substituindo listas tradicionais de preferências por **pontuações de compatibilidade objetivas**, baseadas em métricas como Jaccard, Cosseno e Euclidiana Inversa.:

1. **Inicialização dos Participantes:** Todos os participantes começam “livres”, ou seja, ainda não estão emparelhados. Para cada indivíduo, o sistema calcula as pontuações de compatibilidade em relação a todos os outros participantes. Essas pontuações são organizadas em uma lista ordenada, da maior para a menor compatibilidade.
2. **Propostas Baseadas em Compatibilidade:** O algoritmo segue um fluxo iterativo no qual cada participante, em ordem, faz uma proposta ao colega mais compatível que ainda não recusou anteriormente. Se o proposto estiver “livre”, o par é formado. Caso o proposto já esteja emparelhado, ele aceita a nova proposta somente se ela for mais compatível do que a atual. Se não, rejeita e mantém o par anterior.
3. **Atualização das Listas e Estado dos Pares:** A cada rodada de propostas aceitas ou recusadas, o sistema atualiza as listas de participantes livres e os pares atuais. Os participantes que foram dispensados voltam à lista de livres e passam a propor aos próximos da sua lista, seguindo a ordem de maior compatibilidade. Esse processo garante que, mesmo diante de reatribuições, os pares vão se tornando cada vez mais compatíveis, maximizando a qualidade das correspondências.
4. **Critério de Finalização:** O algoritmo termina quando todos os participantes estão emparelhados ou não há mais possibilidades de emparelhamento que melhorem a compatibilidade total. Esse critério assegura que os pares finais são estáveis no sentido de que não existe outro par possível com maior compatibilidade mútua.

---

**Algoritmo 1:** Gale-Shapley Modificado com Uma Lista
 

---

**Entrada:** Conjunto de indivíduos  $P = \{p_1, p_2, \dots, p_n\}$  e pontuações de compatibilidade  $C$ .

**Saída:** Conjunto de pares  $S$ .

```

1: função GALE_SHAPLEY_MODIFICADO( $P, C$ )
2:   Inicializar:  $S \leftarrow \emptyset$ , PessoasLivres  $\leftarrow P$ 
3:   para cada  $p_i \in P$  faça
4:     Preferências[ $p_i$ ]  $\leftarrow$  ORDENAR_POR_COMPATIBILIDADE( $p_i, C$ )
5:   fim para
6:   enquanto PessoasLivres  $\neq \emptyset$  faça
7:      $p \leftarrow$  ESCOLHER(PessoasLivres)
8:     para cada preferido  $\in$  Preferências[ $p$ ] faça
9:       se preferido está livre ou prefere  $p$  ao par atual então
10:        se preferido está em  $S$  então
11:          Adicionar à lista de livres ( $S[\text{preferido}]$ )
12:        fim se
13:         $S[\text{preferido}] \leftarrow p$ 
14:        Remover ( $p$ ) da lista de livres
15:        interromper
16:      fim se
17:    fim para
18:  fim enquanto
19:  retornar  $S$ 
20: fim função

```

---

### 3.2.4 Diferenças em Relação a Trabalhos Anteriores

Nossa proposta se distingue das abordagens discutidas no Capítulo II, particularmente dos trabalhos de Yusri et al. (2021) e Girard et al. (2021), que, embora aplicados a contextos educacionais, utilizam duas listas de indivíduos. A principal inovação do nosso trabalho está na adaptação do algoritmo de Gale-Shapley para operar com uma única lista e avaliando diversas pontuações de compatibilidade, buscando atender às necessidades de ambientes educacionais colaborativos e competitivos. Nessas situações, os estudantes não fornecem preferências explícitas por outros participantes, sendo avaliados com base em critérios objetivos, como notas ou desempenho em atividades e preferências semelhantes.

Essa modificação traz uma abordagem mais alinhada à realidade educacional, em que o equilíbrio e a compatibilidade entre os pares são importantes para otimizar a experiência de aprendizagem e incentivar a colaboração entre os alunos. Ao invés de focar em preferências individuais, a proposta prioriza a compatibilidade global, criando um ambiente mais harmonioso e eficiente para todos os envolvidos.

### **3.2.5 Desempenho e Escalabilidade**

Para avaliar o desempenho e a escalabilidade do algoritmo modificado, foram realizadas simulações com diferentes tamanhos de grupos de estudantes, variando de 10 a 10.000 participantes. Os resultados mostraram que o algoritmo é eficiente em termos de tempo de execução e capacidade de formar pares estáveis em larga escala. O uso de métricas de compatibilidade e a adaptação para uma única lista permitem que o algoritmo escale de forma eficiente, mesmo em contextos com grandes quantidades de dados, como turmas numerosas ou projetos colaborativos envolvendo muitos participantes. Posteriormente foi testado de forma aplicada utilizando jogos digitais educativos.

## **3.3 Simulação e Avaliação**

A fim de avaliar a eficácia e o desempenho do algoritmo modificado de Gale-Shapley, foi implementada uma metodologia que inclui a utilização de dados sintéticos para simular ambientes educacionais diversos. Esses dados foram gerados com base em atributos numéricos e categóricos, de modo a refletir a complexidade e a heterogeneidade dos perfis estudantis em contextos reais. A abordagem adotada garante que o algoritmo seja testado em diferentes cenários, permitindo uma análise detalhada da sua robustez, escalabilidade e eficiência na formação de pares estáveis e compatíveis.

### 3.3.1 Geração e Normalização de Dados Sintéticos

Os dados sintéticos utilizados nas simulações foram gerados com o intuito de representar a diversidade observada em ambientes educacionais. Os perfis de estudantes foram modelados com atributos como habilidades, desempenho acadêmico, interesses, e outros fatores relevantes para o contexto de aprendizado. Esses atributos incluem variáveis numéricas, como notas e tempo de estudo, e variáveis categóricas, como preferências de estilo de aprendizagem e áreas de interesse.

Um passo para assegurar a comparabilidade das métricas de compatibilidade foi a normalização dos dados. A normalização ajusta os valores dos diferentes atributos para uma escala comum, eliminando possíveis distorções causadas pela variação nas unidades de medida. Isso é essencial para garantir que tanto os atributos numéricos quanto os categóricos sejam tratados de maneira equitativa durante o cálculo das pontuações de compatibilidade. Ao aplicar técnicas de normalização, como o escalonamento dos dados para intervalos padronizados (ex.:  $[0,1]$ ), é possível aumentar a precisão e a objetividade na avaliação da similaridade entre os perfis dos estudantes.

### 3.3.2 Cálculo das Pontuações de Compatibilidade

As pontuações de compatibilidade entre os estudantes foram calculadas utilizando três métricas principais: distância euclidiana inversa, similaridade de Jaccard e similaridade cosseno. Cada uma dessas métricas oferece uma perspectiva única sobre a similaridade entre os indivíduos:

- **Distância Euclidiana Inversa:** Avalia a proximidade entre os perfis numéricos dos participantes, medindo a distância entre eles em um espaço multidimensional. Esta métrica foi invertida para que maiores valores representassem maior compatibilidade.
- **Similaridade de Jaccard:** Comparou as semelhanças e diferenças nos conjuntos de atributos categóricos dos estudantes, como preferências de estilo de aprendizagem, analisando a proporção entre a interseção e a união desses atributos.
- **Similaridade Cosseno:** Usada para medir a similaridade angular entre os vetores que representam os perfis dos estudantes, sendo eficaz em contextos onde a magnitude dos dados pode variar, mas a direção é mais relevante.

Essas métricas foram integradas à execução do algoritmo modificado para formar pares com a maior compatibilidade possível. Cada estudante teve sua lista de possíveis pares ordenada de acordo com as pontuações de compatibilidade, garantindo que os pares formados maximizassem a afinidade entre os participantes.

### 3.3.3 Implementação e Execução das Simulações

As simulações foram conduzidas com o objetivo de avaliar a robustez, eficiência e escalabilidade do algoritmo modificado. Diferentes conjuntos de dados sintéticos foram gerados para simular populações de tamanhos variados, incluindo 10, 100, 1.000 e 10.000 indivíduos. Esses tamanhos foram escolhidos para testar o algoritmo em diferentes escalas e verificar sua capacidade de formar pares estáveis e satisfatórios em contextos que vão desde pequenos grupos de estudantes até grandes turmas ou equipes.

As simulações seguiram as seguintes etapas:

1. **Inicialização dos Conjuntos de Dados:** Cada conjunto de dados foi gerado com base nos perfis dos estudantes, contendo atributos categóricos e numéricos que foram normalizados.
2. **Execução do Algoritmo Modificado:** O algoritmo foi executado para formar pares de estudantes de acordo com as pontuações de compatibilidade. Cada estudante propôs emparelhamentos com base na sua lista ordenada, e os pares foram formados conforme as regras descritas no Capítulo 3.1.3.
3. **Avaliação dos Resultados:** Após a formação dos pares, diversas métricas foram utilizadas para avaliar a qualidade dos emparelhamentos. As métricas principais incluíram:
  - **Tempo de Execução:** O tempo necessário para o algoritmo formar todos os pares, uma medida importante de sua eficiência em diferentes escalas.
  - **Taxa de Sucesso na Formação de Pares Estáveis:** Avalia a proporção de pares formados que satisfazem as condições de estabilidade, ou seja, pares que não possuem preferências mútuas por outros parceiros que não estejam emparelhados.

4. **Análise Estatística:** Os resultados foram analisados estatisticamente para identificar padrões de desempenho do algoritmo. Comparações entre os diferentes tamanhos de conjuntos de dados foram realizadas para verificar a escalabilidade do algoritmo, enquanto métricas de compatibilidade foram comparadas para avaliar a eficácia de cada uma em diferentes cenários.

## 3.4 Teste com Jogos Educacionais

Nesta seção, detalhamos a metodologia dos testes realizados com jogos digitais educacionais, utilizada para avaliar o impacto da formação de pares por meio do algoritmo modificado de Gale-Shapley. Os testes foram baseados em dados coletados durante a execução de um jogo educativo chamado "Labirinto da Educação", no qual os estudantes participaram de desafios interativos para aprimorar suas habilidades linguísticas, com foco no aprendizado do inglês. O jogo, disponível na plataforma Educapes, foi escolhido por sua flexibilidade e capacidade de adaptação do conteúdo educacional, além de seu caráter de código aberto.

### 3.4.1 Ambiente do Jogo Digital

Este estudo utilizou o jogo 'Labirinto da Educação' do portal Educapes<sup>6</sup>. Escolhemos este jogo devido à sua flexibilidade, à possibilidade de personalizar o conteúdo em inglês e à sua natureza de código aberto. Este jogo educativo digital apresenta salas com desafios interativos para melhorar a aprendizagem dos alunos.

Situado num labirinto virtual, os alunos navegam por meio dele para encontrar e resolver desafios. Cada sala é um desafio interativo que exige a aplicação de competências linguísticas como a compreensão da leitura, a gramática e o vocabulário. Os alunos recebem *feedback* imediato sobre as suas respostas e só podem avançar no labirinto quando tiverem a resposta correta, ajudando-os a corrigir erros e a compreender melhor o conteúdo. Além disso, os puzzles variam em dificuldade para manter os alunos desafiados sem os sobrecarregar.

---

<sup>6</sup> <http://educapes.capes.gov.br/handle/capes/586677>

### 3.4.2 Formação dos Grupos

A amostra do estudo foi composta por 20 estudantes, divididos em dois grupos: um experimental e um de controle. O grupo experimental foi formado utilizando o algoritmo de Gale-Shapley modificado, no qual os pares foram determinados com base na similaridade de desempenho acadêmico, calculada por meio do coeficiente de similaridade de Jaccard. Já o grupo de controle teve seus pares formados aleatoriamente.

### 3.4.3 Coleta de Dados

Foram incluídos alunos matriculados no curso de inglês de uma escola federal de ensino médio do Paraná, Brasil, com idades entre 18 e 20 anos. A amostra foi composta por 20 indivíduos, sendo 12 do sexo masculino e oito do sexo feminino. Dividimos os alunos em dois grupos: um grupo experimental (pares formados pelo algoritmo modificado) e um grupo controle (pares formados aleatoriamente). Ambos os grupos participaram no jogo “Labirinto da Educação”, onde foi registrado suas interações e desempenho. Após a conclusão do jogo, aplicamos um questionário para recolher o *feedback* dos alunos sobre a sua satisfação, envolvimento, conforto e percepção da aprendizagem.

Os instrumentos de recolha incluíram um questionário de satisfação e dados de desempenho. O questionário de satisfação incluía perguntas sobre a satisfação, as ajudas à aprendizagem, o envolvimento, a eficácia do jogo, a dificuldade dos desafios, a motivação e a contribuição para a aprendizagem. O sistema de jogo recolheu automaticamente dados de desempenho, incluindo a pontuação média, o número de respostas corretas e erradas e o tempo médio e total gasto nas tarefas.

Os dados quantitativos foram analisados utilizando estatísticas descritivas e inferenciais para comparar os desempenhos dos grupos experimental e de controle. Analisamos os dados qualitativos do questionário de forma temática para identificar padrões e percepções das experiências dos participantes.

### 3.4.4 Anonimização dos dados

Garantimos a privacidade dos participantes por meio da anonimização dos dados de acordo com as diretrizes da Lei Geral de Proteção de Dados Pessoais (LGPD)<sup>7</sup> e as normas éticas da investigação acadêmica. Utilizamos identificadores únicos gerados aleatoriamente para registrar os pares e o desempenho. Anonimizamos os dados substituindo as informações identificáveis por códigos criptográficos, garantindo a segurança e a privacidade dos dados. Além disso, não recolhemos dados sensíveis, como nomes, endereços ou outras informações pessoais, excluindo-os do conjunto de dados desde o início.

Os dados anonimizados foram armazenados em servidores seguros com acesso restrito, utilizando tecnologias de *firewall*, encriptação de dados em trânsito e em repouso, e controles de acesso rigorosos. O pessoal autorizado teve acesso aos dados e os registros de auditoria registraram todas as operações de acesso e modificação para garantir a transparência e a rastreabilidade.

Adotamos esses procedimentos para garantir a conformidade com a LGPD brasileira, regulamentações que estabelecem padrões para a proteção de dados pessoais, garantindo os direitos fundamentais de privacidade e segurança dos indivíduos. Ao cumprir essas leis, conduzimos a pesquisa de forma ética e legal, protegendo os direitos e a privacidade dos participantes em todas as etapas.

Esta pesquisa foi aprovada pelo Comitê de Ética em Pesquisa da Universidade Estadual de Campinas (CEP/UNICAMP), conforme o parecer substanciado nº 7.180.702 e o CAAE nº 83762924.3.0000.5404. A aprovação garante que todos os procedimentos envolvendo participantes humanos foram conduzidos de acordo com os princípios éticos estabelecidos pela Resolução nº 510/2016 e pela Resolução nº 466/2012 do Conselho Nacional de Saúde. Todos os dados coletados foram devidamente anonimizados, e os participantes foram informados sobre seus direitos por meio de Termo de Consentimento Livre e Esclarecido (TCLE), conforme exigido pela Plataforma Brasil.

---

<sup>7</sup> <https://lcpd-brazil.info/>

# Capítulo 4

## Resultados e Análise

### 4.1 Simulação em SEL

Esta seção 4.1 analisa os resultados da implementação e comparação do algoritmo de emparelhamento Gale-Shapley modificado. Foi avaliada a eficiência e a eficácia do algoritmo utilizando conjuntos de dados de diferentes tamanhos e composições gerados por meio do pacote Synthetic Data Vault (SDV)<sup>8</sup> e do NumPy<sup>9</sup>. Foi explorado como diferentes atributos numéricos e categóricos influenciam a formação de pares com base em pontuações de compatibilidade. Utilizando visualizações como gráficos de caixa, de barras e de linhas para examinar a distribuição da compatibilidade, o impacto do tamanho do conjunto de dados e as interações entre várias métricas de compatibilidade.

#### 4.1.1 Geração de Dados

A geração de dados permite a modelagem e análise de algoritmos quando os dados não estão disponíveis, são confidenciais ou estão incompletos. O pacote SDV simulou dados com atributos numéricos e categóricos, enquanto o NumPy gerou dados puramente numéricos. Estas abordagens permitiram-nos avaliar os algoritmos de correspondência em várias condições, fornecendo informações sobre a sua eficácia e adaptabilidade.

O SDV gera dados sintéticos complexos, simulando conjuntos de dados multidimensionais que refletem a diversidade do mundo real. Foi utilizado o SDV para criar conjuntos de dados com vários atributos. Isto envolveu a normalização e a codificação *one-hot* com *OneHotEncoder*<sup>10</sup>, convertendo dados categóricos em matrizes binárias para

---

<sup>8</sup> <https://docs.sdv.dev/sdv>

<sup>9</sup> <https://numpy.org/>

<sup>10</sup> <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.OneHotEncoder.html>

inclusão em cálculos de compatibilidade. A normalização com o *Min-Max*<sup>11</sup> ajustou os valores dos dados numéricos a uma escala padrão de 0 a 1, garantindo que cada atributo contribuísse igualmente para as métricas de compatibilidade.

Para além da abordagem SDV, utilizamos a biblioteca NumPy para gerar um segundo conjunto de dados centrado exclusivamente em atributos numéricos. Este protocolo assegurou a reprodutibilidade e a consistência, permitindo uma comparação direta do desempenho dos algoritmos de emparelhamento num ambiente controlado.

Tabela 1 - Amostra de dados gerados pelo SDV antes da normalização

Interesses	Estilo de Aprendizagem	Preferência de Estudo	Proficiência Matemática	Proficiência em Leitura	Proficiência em Ciências	Proficiência em Escrita	Competências de Resolução de Problemas	Habilidades Sociais
Artes	Auditivo	Grupo	60,14	29,48	88,61	46,95	17,07	66,94
Literatura	Cinestésico	Grupo	37,29	87,42	6,38	52,95	8,26	28,33
Artes	Auditivo	Individual	36,53	32,82	40,49	40,36	82,33	55,02
Esportes	Auditivo	Individual	51,51	27,31	85,49	67,81	75,97	85,09
Esportes	Cinestésico	Individual	38,06	2,52	6,29	58,50	12,88	49,91
Artes	Visual	Grupo	58,34	16,63	97,60	45,32	24,97	70,70
Esportes	Leitura / Escrita	Grupo	37,14	66,91	72,74	66,40	7,72	8,13

Fonte: Pinheiro Junior (2024).

A Tabela 1 mostra uma amostra dos dados antes da normalização, incluindo dados numéricos e categóricos em formato de texto.

<sup>11</sup> <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.MinMaxScaler.html>

Tabela 2 - Amostra de dados após a normalização e a codificação *one-hot*

Proficiência Matemática	Proficiência em Leitura	Proficiência em Ciências	Interesses em Artes	Interesses Literatura	Interesses Ciências	Interesses Esportes	Preferência de Estudo em Grupo	Preferência de Estudo Individual
0,4801	0,2889	0,8911	1	0	0	0	1	0
0,0617	0,8940	0,0539	0	1	0	0	1	0
0,0478	0,3238	0,4013	1	0	0	0	0	1
0,4719	0,3802	0,7282	0	1	0	0	0	1
0,3220	0,2663	0,8594	0	0	0	1	0	1
0,2875	0,6999	0,3815	0	1	0	0	1	0
0,0757	0,0074	0,0530	0	0	1	0	0	1
0,4471	0,1547	0,9827	1	0	0	0	1	0
0,0589	0,6798	0,7296	0	0	0	1	1	0
0,3632	0,2600	0,2202	0	0	0	1	0	1

Fonte: Pinheiro Junior (2024).

Observa-se na Tabela 2 que, após a normalização, os valores dos atributos numéricos estão entre 0 e 1, garantindo que cada atributo contribua igualmente para o cálculo das métricas de compatibilidade. Isso evita que atributos com valores numericamente maiores influenciem desproporcionalmente os resultados. As seções a seguir discutirão os resultados do cálculo de métricas e do algoritmo de Gale-Shapley modificado aplicadas a esses conjuntos de dados simulados.

#### **4.1.2 Cálculo das pontuações de compatibilidade (métrica de compatibilidade).**

Foi feita a análise dos resultados do cálculo da métrica e a aplicação pelo algoritmo de Gale-Shapley de várias métricas de compatibilidade, incluindo a distância euclidiana inversa, a similaridade de Jaccard e a similaridade de cosseno. Estas métricas avaliaram a qualidade do emparelhamento e o tempo de execução. A escolha da métrica de compatibilidade também afeta o tempo de execução do algoritmo de emparelhamento, variando a complexidade computacional para cada métrica. Por conseguinte, a seleção da métrica mais adequada com base no conjunto de dados e nos requisitos da aplicação é necessário para equilibrar a precisão

da compatibilidade e a eficiência computacional. Os detalhes sobre o cálculo das pontuações de compatibilidade de cada métrica foram apresentados no Capítulo 3.1.

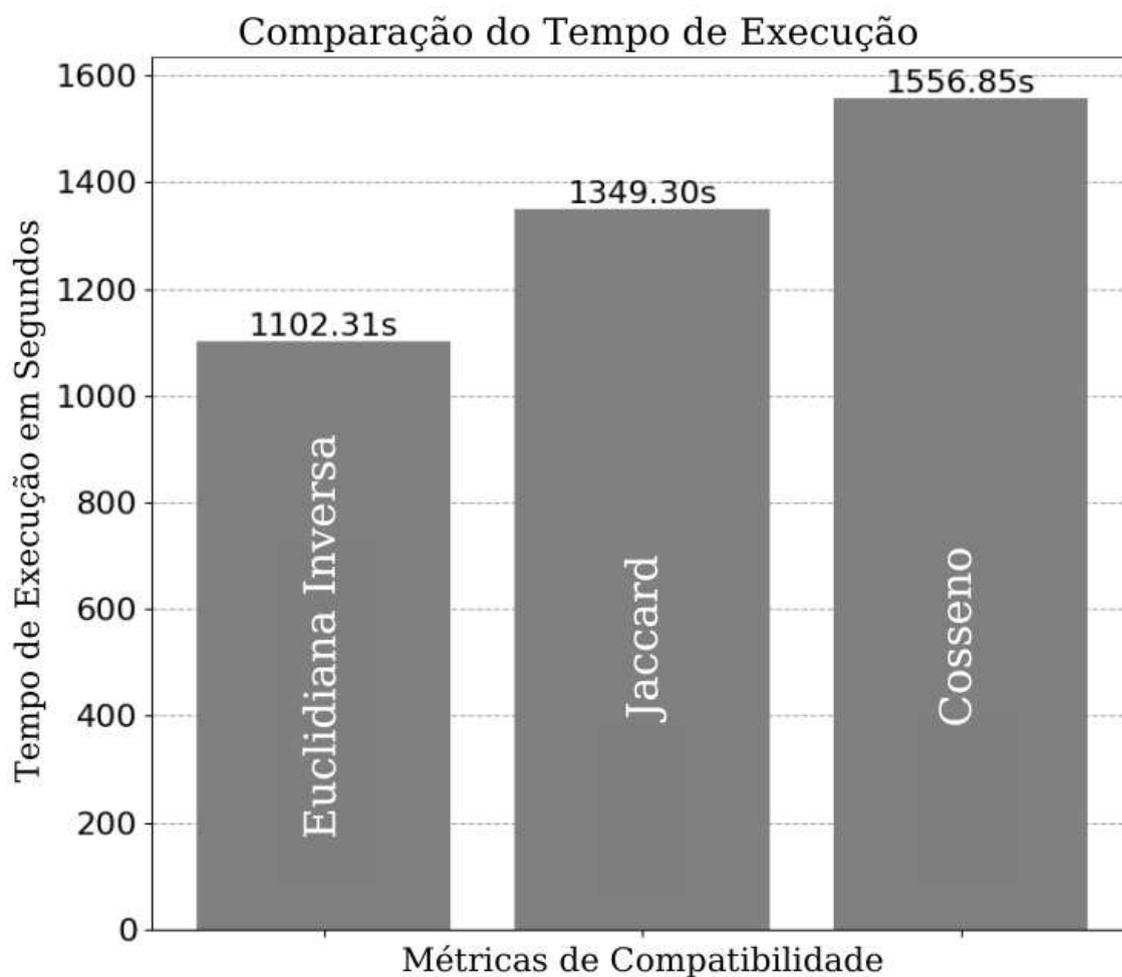


Figura 1 - Gráfico do tempo de execução da pontuação de compatibilidade (dados numéricos).

Fonte: Pinheiro Junior (2024).

A Figura 1 compara os tempos de execução para calcular a métrica de compatibilidade com 10.000 indivíduos utilizando dados numéricos normalizados.

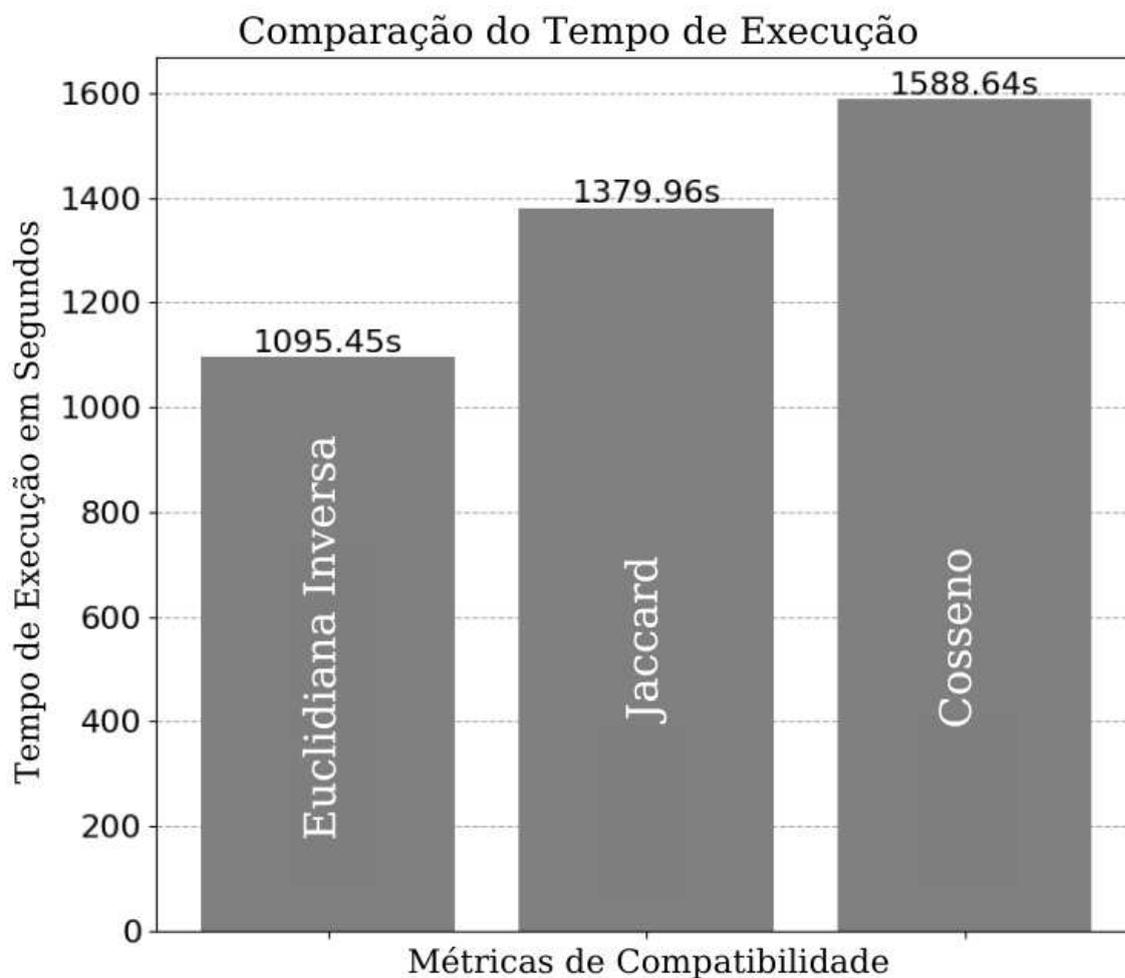


Figura 2 - Gráfico que mostra o tempo necessário para calcular a pontuação de compatibilidade (dados numéricos e categóricos). Fonte: Pinheiro Junior (2024).

A Figura 2 compara os tempos de execução para calcular as métricas de compatibilidade com 10.000 indivíduos usando dados numéricos e categóricos. Observa-se que a distância euclidiana inversa apresentou o menor tempo de execução devido à sua simplicidade computacional. Em contraste, a similaridade de cosseno, apesar de oferecer alta precisão em dados de alta dimensão, requer cálculos mais intensivos, o que aumenta o tempo de processamento.

Ambas figuras implementam diferentes métricas de compatibilidade, que fornecem informações sobre a forma como os métodos de avaliação influenciam os algoritmos de emparelhamento. Uma métrica adequada é fundamental para obter emparelhamentos de alta qualidade, mantendo a eficiência computacional.



Figura 3 - Mapa de calor das pontuações de compatibilidade euclidiana inversa.

Fonte: Pinheiro Junior (2024).

O mapa de calor da Figura 3 apresenta as pontuações de compatibilidade euclidiana inversa normalizada entre os alunos para identificar os pares ideais para a aprendizagem em colaboração. Pares de alta compatibilidade, indicados por células mais escuras, sugerem alunos com maior probabilidade de formar pares estáveis, pois têm uma preferência mútua maior. Por outro lado, as células mais claras representam pares de compatibilidade mais baixa, indicando pares com menor compatibilidade.

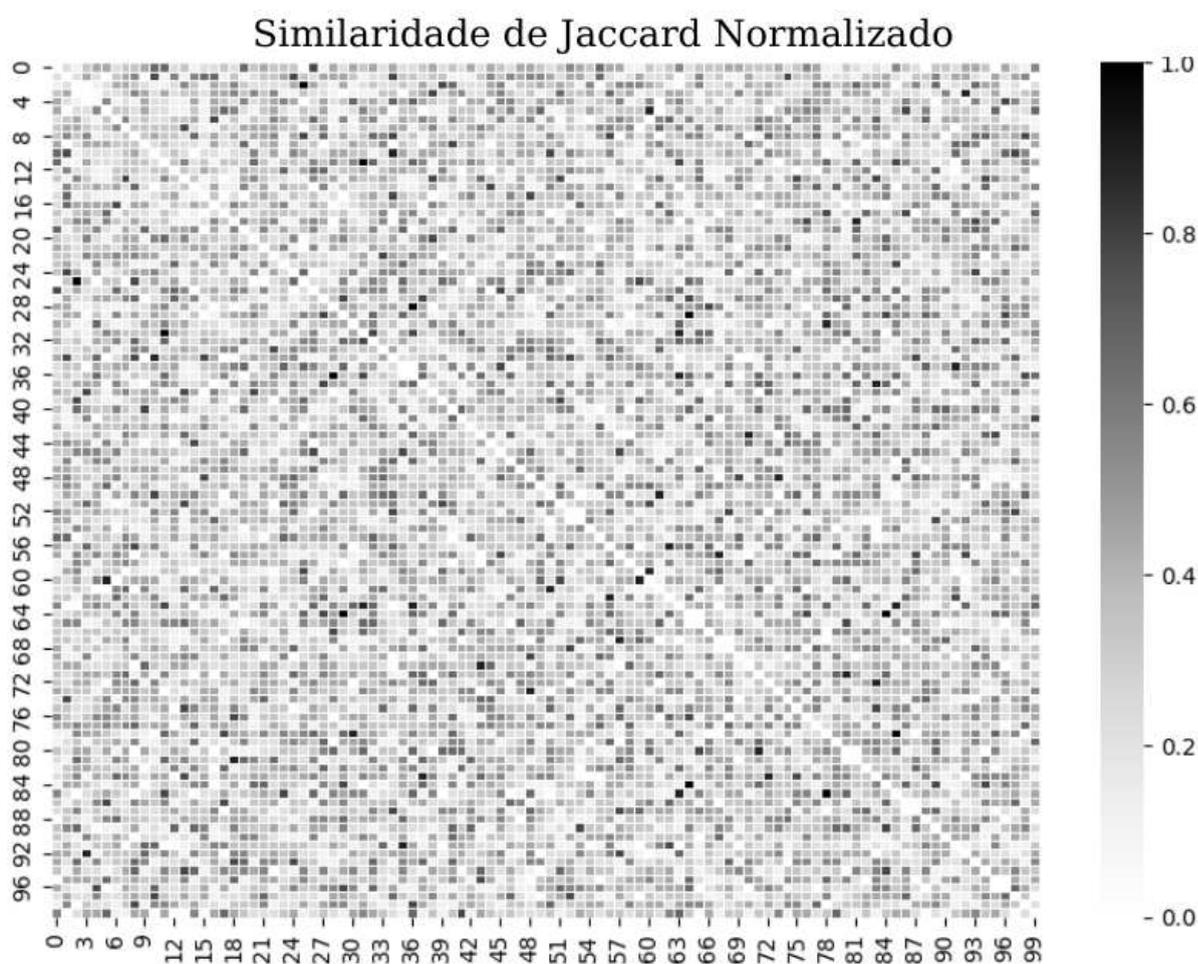


Figura 4 - Mapa de calor das pontuações de compatibilidade de similaridade de Jaccard.

Fonte: Pinheiro Junior (2024).

Da mesma forma, o mapa de calor da Figura 4 ilustra as pontuações de compatibilidade normalizadas de Jaccard entre os alunos, com o objetivo de identificar os pares ideais para a aprendizagem em colaboração. Pares de alta compatibilidade, representados por células mais escuras, indicam alunos com maior preferência mútua, sugerindo combinações estáveis. Em contraste, as células mais claras denotam uma compatibilidade mais baixa, indicando pares menos favoráveis.

Por último, o mapa de calor da Figura 5 mostra a semelhança entre pares de alunos com base na métrica de semelhança de cosseno. O padrão apresenta faixas horizontais e verticais distintas, indicando grupos de compatibilidade consistentes em que grupos específicos de alunos apresentam maior ou menor compatibilidade em relação a outros. Este agrupamento sugere que certos grupos de alunos partilham perfis de compatibilidade

semelhantes, tornando a métrica do cosseno particularmente eficaz para identificar e formar grupos coesos para a aprendizagem em colaboração. A linha diagonal uniforme confirma a auto-similaridade máxima, reforçando a consistência da normalização em todo o conjunto de dados.

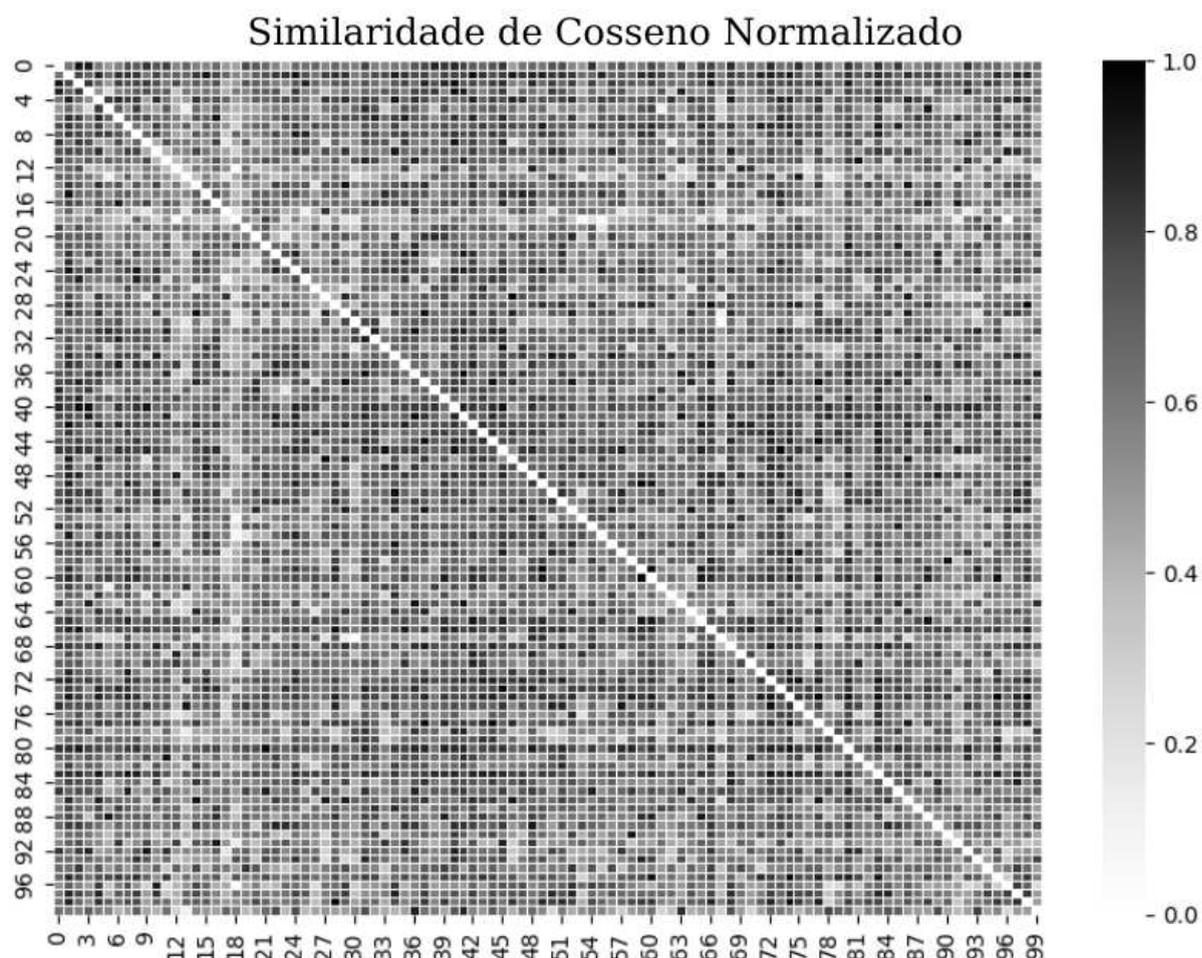


Figura 5 - Mapa de calor das pontuações de similaridade de cosseno.

Fonte: Pinheiro Junior (2024).

A comparação dos mapas de calor para as pontuações de compatibilidade euclidiana inversa, Jaccard e cosseno normalizado revela padrões distintos na compatibilidade dos alunos para a aprendizagem colaborativa. O mapa de calor do euclidiano inverso mostra uma distribuição de compatibilidade diversa, indicando uma variação significativa na similaridade entre pares. O mapa de calor Jaccard apresenta uma distribuição mais uniforme, sugerindo níveis de compatibilidade moderados na maioria dos pares, adequados para dados binários ou categóricos. O mapa de calor da similaridade cosseno apresenta bandas horizontais e verticais

claras, indicando grupos de compatibilidade consistentes entre grupos de alunos específicos. Estas diferenças realçam a importância de selecionar as métricas adequadas com base nas características dos dados e nos objetivos do emparelhamento, com cada métrica a fornecer informações únicas sobre a compatibilidade dos alunos.

### 4.1.3 Avaliação de métricas de compatibilidade em algoritmos de emparelhamento com dados numéricos

Analizamos os resultados da aplicação de várias métricas de compatibilidade - distância euclidiana inversa, semelhança de Jaccard e semelhança de cosseno - ao algoritmo de Gale-Shapley modificado utilizando conjuntos de dados numéricos. Esta análise forneceu informações sobre a natureza e a interpretação das pontuações de compatibilidade, especialmente em comparação com um modelo de emparelhamento aleatório, do ponto de vista da eficiência (a estabilidade dos pares emparelhados) e da eficácia (o custo computacional do emparelhamento).

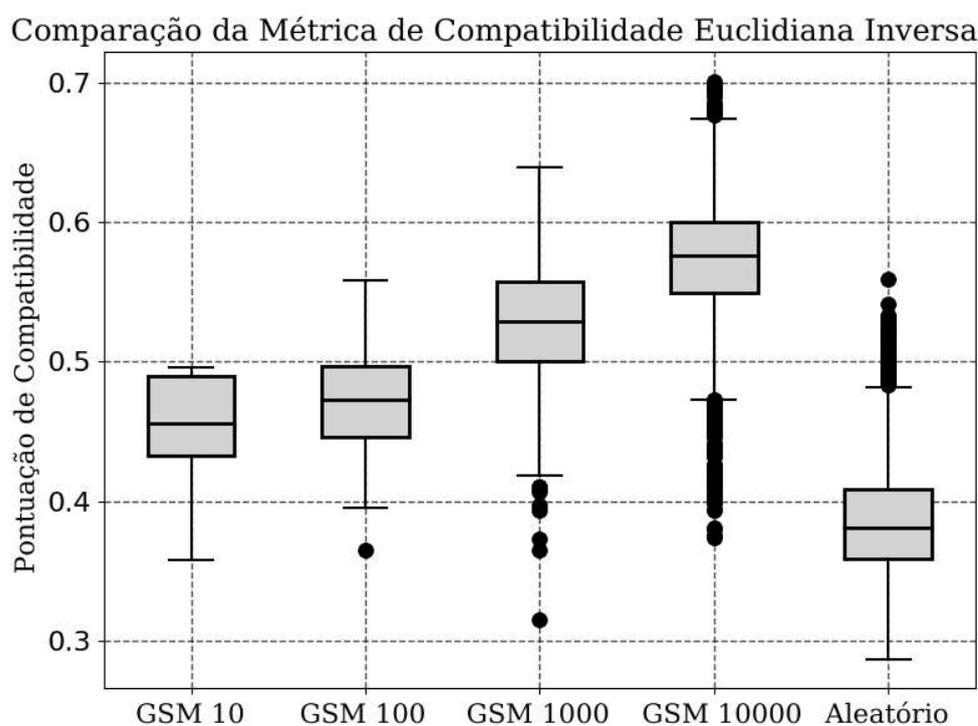


Figura 6 - Gráfico das distribuições de emparelhamento utilizando as pontuações de compatibilidade euclidiana inversa no conjunto de dados numéricos. Fonte: Pinheiro Junior (2024).

A Figura 6 apresenta um diagrama de caixa que compara os emparelhamentos gerados pelo algoritmo de Gale-Shapley modificado utilizando as pontuações de compatibilidade euclidiana inversa. Os grupos variam de 10 a 10.000 indivíduos, incluindo um grupo gerado aleatoriamente de 10.000. Cada caixa no gráfico representa o intervalo interquartil (IQR) das pontuações de compatibilidade, com a linha interna indicando a mediana. As linhas, também chamadas de bigodes, se estendem até os valores mais extremos dentro dos limites, excluindo os valores atípicos, que são destacados por círculos, representando os pontos discrepantes.

Tabela 3 - Dados de emparelhamento utilizando pontuações de compatibilidade euclidiana inversa em conjuntos de dados numéricos.

	<b>média</b>	<b>mínimo</b>	<b>25%</b>	<b>mediana</b>	<b>75%</b>	<b>máximo</b>	<b>tempo de execução</b>	<b>iterações</b>
GSM 10	0,4467	0,3585	0,4329	0,4559	0,4902	0,4961	0,0002	13
GSM 100	0,4734	0,3649	0,4458	0,4733	0,4965	0,5585	0,0141	141
GSM 1000	0,5268	0,3152	0,5007	0,5286	0,5577	0,6394	1,3406	1.448
GSM 10000	0,5724	0,3740	0,5490	0,5762	0,6000	0,7010	167,9475	14.579
Aleatório	0,3863	0,2973	0,3591	0,3831	0,4085	0,6695	0,0037	

Fonte: Pinheiro Junior (2024).

A Tabela 3 mostra os dados utilizados para gerar a Figura 6. Indica que o GSM 10 tem a pontuação média de compatibilidade mais baixa (0,4467) com um desvio padrão de 0,0498. O GSM 10000 teve a pontuação média mais elevada (0,5724) com um desvio padrão ligeiramente inferior (0,0418). O grupo gerado aleatoriamente teve a pontuação média mais baixa (0,3863) com um desvio padrão semelhante ao do GSM 10000. O tempo de execução e as iterações variaram significativamente, com o GSM 10000 gerando o maior tempo de execução (167,9475 segundos) e iterações (14.579), enquanto o GSM 10 teve o menor tempo de execução (0,0002 segundos) e iterações (13).

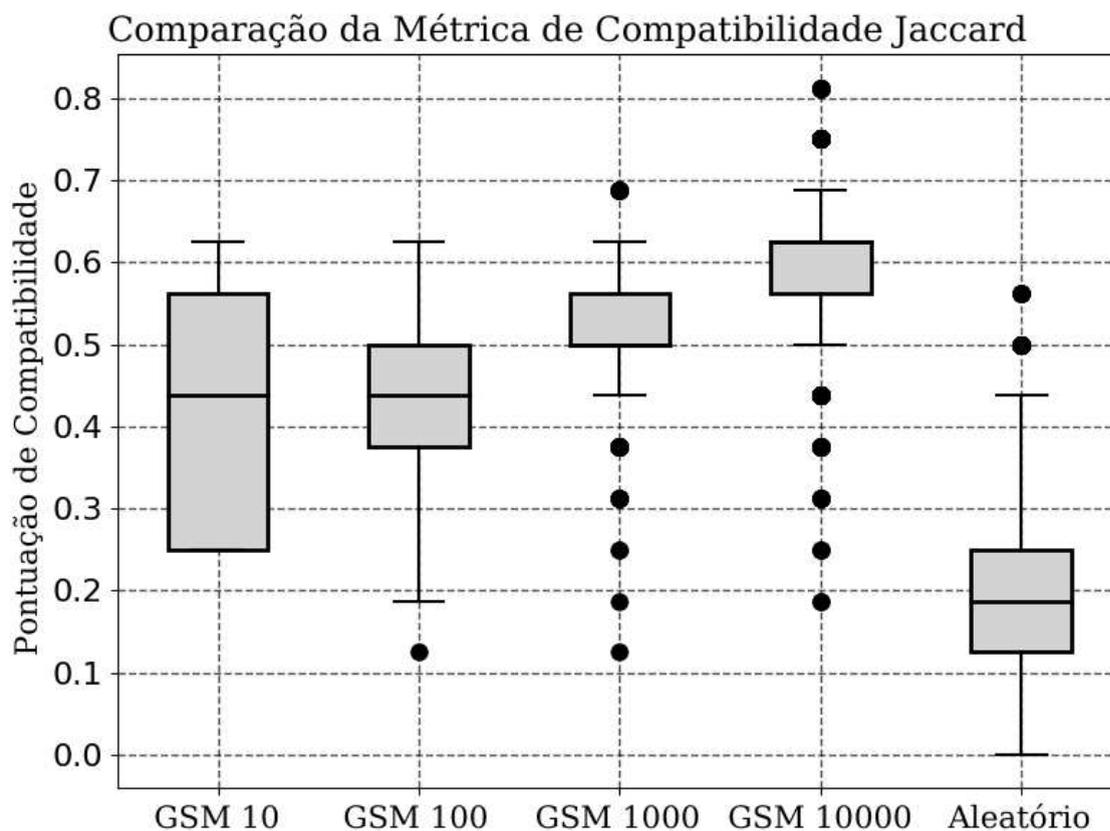


Figura 7 - Gráfico das distribuições de emparelhamento utilizando as pontuações de compatibilidade Jaccard no conjunto de dados numéricos. Fonte: Pinheiro Junior (2024).

A Figura 7 apresenta um diagrama de caixa das distribuições de pares utilizando as pontuações de compatibilidade do índice de Jaccard. Tal como na Figura 6, o gráfico examina grupos de GSM 10 a GSM 10000 e inclui um grupo aleatório de 10 000 indivíduos.

Tabela 4 - Dados de emparelhamento utilizando pontuações de compatibilidade de Jaccard em conjuntos de dados numéricos.

	média	mínimo	25%	mediana	75%	máximo	tempo de execução	iterações
GSM 10	0,4444	0,2500	0,2500	0,4375	0,5625	0,6250	0,0002	13
GSM 100	0,4306	0,1250	0,3750	0,4375	0,5000	0,6250	0,0146	122
GSM 1000	0,5257	0,1250	0,5000	0,5000	0,5625	0,6875	1,2894	1.259
GSM 10000	0,6032	0,1875	0,5625	0,6250	0,6250	0,8125	145,2004	12.203
Aleatório	0,1900	0,0000	0,1250	0,1875	0,2500	0,5625	0,0037	

Fonte: Pinheiro Junior (2024).

A Tabela 4 mostra que o GSM 10 teve uma pontuação média de compatibilidade de 0,4444 com um desvio padrão elevado de 0,1515. O GSM 100 teve uma média ligeiramente inferior de 0,4306 com um desvio-padrão de 0,0779. O GSM 1000 apresentou uma média mais elevada de 0,5257 com um desvio padrão de 0,0702. O GSM 10000 teve a pontuação média mais elevada de 0,6032 com um desvio padrão de 0,0600. O grupo aleatório teve uma média significativamente inferior (0,1900) com um desvio-padrão alargado (0,0985). O tempo de execução e as iterações variaram, com o GSM 10000 a necessitar de 145,2004 segundos e 12.203 iterações, enquanto o GSM 10 necessitou apenas de 0,0002 segundos e 13 iterações.

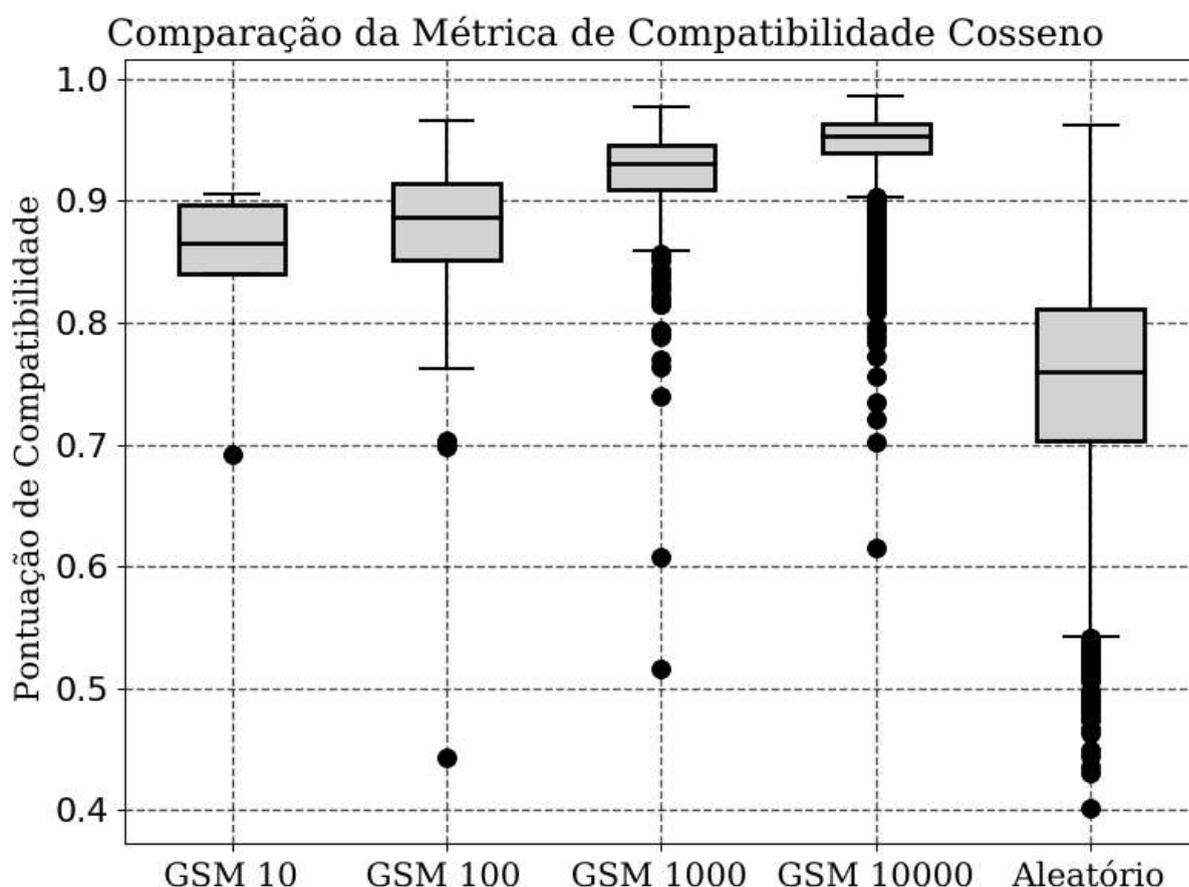


Figura 8 - Gráfico de distribuições de emparelhamento utilizando as pontuações de compatibilidade de cosseno no conjunto de dados numéricos. Fonte: Pinheiro Junior (2024).

A Figura 8 apresenta um diagrama de caixa das distribuições de pares utilizando as pontuações de similaridade de cosseno. Os grupos variam de GSM 10 a GSM 10000 e incluem um grupo aleatório de 10 000 indivíduos.

Tabela 5 - Dados de emparelhamento utilizando as pontuações de compatibilidade de cosseno no conjunto de dados numéricos. Fonte: Pinheiro Junior (2024).

	média	mínimo	25%	mediana	75%	máximo	tempo de execução	iterações
GSM 10	0,8398	0,6922	0,8399	0,8648	0,8970	0,9050	0,0016	12
GSM 100	0,8682	0,4430	0,8517	0,8860	0,9143	0,9652	0,1036	158
GSM 1000	0,9214	0,5163	0,9098	0,9302	0,9451	0,9770	3,6140	1.511
GSM 10000	0,9476	0,6156	0,9389	0,9530	0,9629	0,9863	152,3835	15.004
Aleatório	0,7534	0,4018	0,7034	0,7594	0,8109	0,9615	0,0036	

Fonte: Pinheiro Junior (2024).

A Tabela 5 mostra que o GSM 10 teve uma pontuação de compatibilidade média de 0,8398 com um desvio padrão de 0,0774. O GSM 100 teve uma média de 0,8682 com um desvio padrão de 0,0823. O GSM 1000 teve uma média de 0,9214 com um desvio padrão de 0,0408. O grupo GSM 10000 registrou a média mais elevada de 0,9476 com o desvio padrão mais baixo (0,0243). O grupo aleatório teve uma média mais baixa (0,7534) com um desvio padrão de 0,0790. O tempo de execução e as iterações aumentaram com o tamanho do grupo, com o GSM 10000 a necessitar de 152,3835 segundos e 15.004 iterações, enquanto o GSM 10 necessitou apenas de 0,0016 segundos e 12 iterações.

Apesar das diferenças numéricas entre as métricas, a comparação entre as métricas de compatibilidade e o emparelhamento aleatório indica a necessidade de reavaliar a eficácia percebida. Pontuações de compatibilidade elevadas, principalmente com a similaridade de Cosseno, não implicam necessariamente em pares mais eficientes. Por exemplo, a semelhança de cosseno gerou pontuações elevadas mesmo para emparelhamentos aleatórios, o que levanta dúvidas sobre a correlação direta entre pontuações elevadas e a qualidade dos emparelhamentos. Estes resultados sugerem que os valores de compatibilidade podem refletir as características da métrica e não a qualidade real dos pares formados (ver Figura 8).

A análise visual dos gráficos (Figuras 6, 7 e 8) revelam padrões consistentes na forma como as métricas respondem ao aumento do tamanho do conjunto de dados. As métricas podem diferenciar entre emparelhamentos aleatórios e aqueles baseados em compatibilidade, enfatizando a importância de avaliar as métricas em relação a uma linha de base aleatória. A avaliação qualitativa juntamente com as métricas quantitativas ajudam na interpretação dos

resultados. Embora as métricas forneçam uma base comparativa, os investigadores devem avaliar os algoritmos práticos de emparelhamento por meio de pontuações numéricas e da percepção da relevância e satisfação dos pares formados. Uma análise comparativa revela um compromisso entre a qualidade do emparelhamento e a eficiência computacional. A métrica de cosseno produz os pares mais compatíveis, mas requer mais iterações e tempo de execução.

A métrica de Jaccard oferece uma combinação equilibrada de qualidade de emparelhamento e eficiência computacional, tornando-a viável para aplicações práticas que exijam uma elevada qualidade de emparelhamento sem tempo computacional excessivo. Em comparação com os emparelhamentos aleatórios, o algoritmo GSM melhora a estabilidade e a compatibilidade dos emparelhamentos nas três métricas (euclidiano inverso, Jaccard e cosseno). Para o euclidiano inverso e Jaccard, uma tendência clara de aumento da estabilidade e compatibilidade com valores mais elevados de GSM sugere que o ajuste fino dos parâmetros do algoritmo pode melhorar significativamente a qualidade do emparelhamento. A similaridade de cosseno, por outro lado, apresenta pontuações de compatibilidade intrinsecamente elevadas, indicando a sua robustez para o emparelhamento mesmo com valores de GSM mais baixos, embora se verifiquem melhorias com definições de GSM mais elevadas.

Além disso, o GSM 10000 produz consistentemente os pares mais estáveis e compatíveis em todas as métricas, sugerindo que é uma configuração que permite maximizar a estabilidade do emparelhamento. As pontuações consistentemente mais baixas e mais variáveis para pares aleatórios sublinham a importância de utilizar um algoritmo estruturado para obter pares de alunos estáveis e compatíveis. Estes conhecimentos são cruciais para o desenvolvimento e aplicação de algoritmos para otimizar os pares de alunos para a aprendizagem colaborativa, garantindo que os pares formados são estáveis e altamente compatíveis.

Estes resultados realçam a importância de selecionar cuidadosamente as métricas de compatibilidade para otimizar os algoritmos de emparelhamento. A escolha depende da natureza dos dados e dos requisitos específicos da aplicação. Os resultados demonstram a adaptabilidade do algoritmo GS modificado a diferentes métricas e conjuntos de dados, oferecendo informações valiosas para a implementação de sistemas de recomendação e outras aplicações de emparelhamento baseadas em dados.

#### 4.1.4 Avaliação das métricas de compatibilidade: Inclusão de dados categóricos e numéricos

O algoritmo de Gale-Shapley modificado foi analisado utilizando diferentes métricas de compatibilidade - distância euclidiana inversa, Jaccard e Cosseno - em conjuntos de dados enriquecidos com dados categóricos e numéricos gerados pelo SDV. Em comparação com os conjuntos de dados apenas numéricos, estes conjuntos de dados enriquecidos fornecem uma perspectiva mais complexa e representativa das interações humanas. Uma análise detalhada, utilizando o desempenho do emparelhamento aleatório como linha de base, oferece uma visão crítica da eficácia das métricas na captação da compatibilidade entre vários atributos.

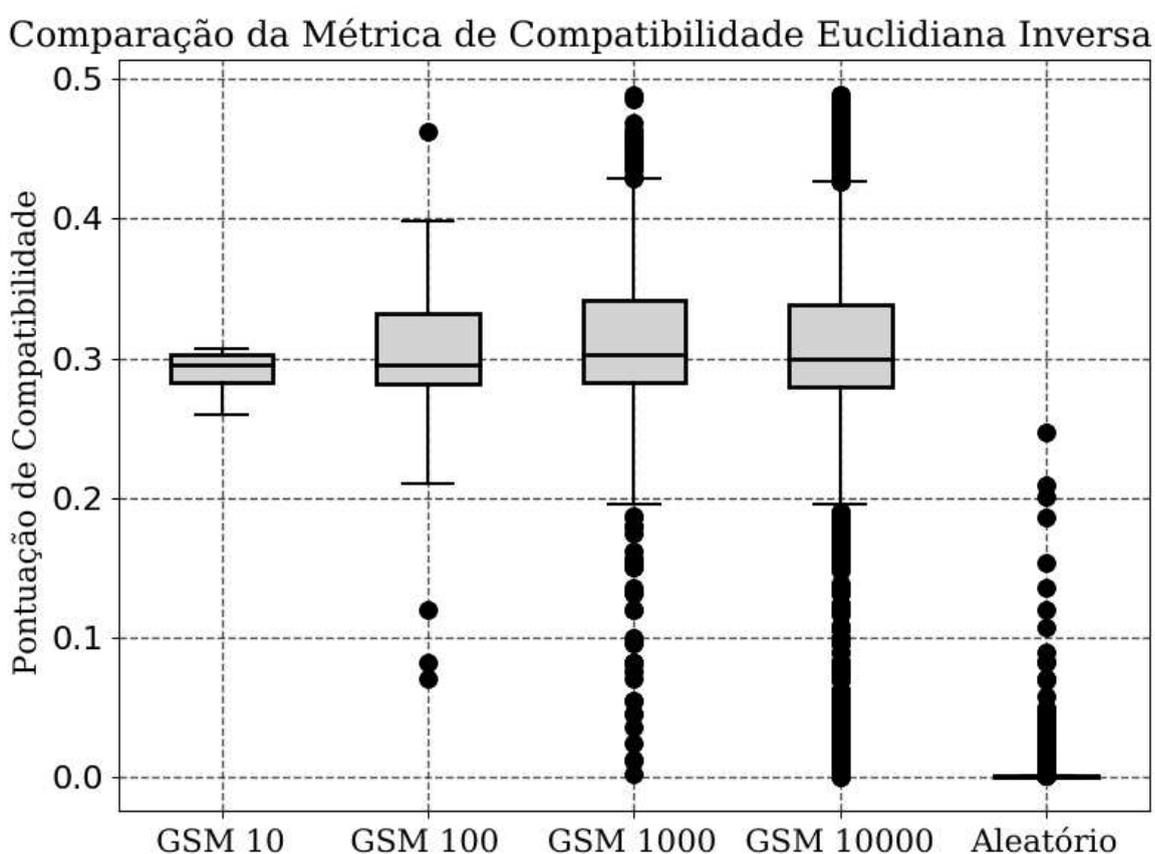


Figura 9 - Gráfico das distribuições de emparelhamento utilizando pontuações de compatibilidade euclidiana inversa em conjuntos de dados numéricos e categóricos.

Fonte: Pinheiro Junior (2024).

A Figura 9 mostra o gráfico de caixa para as distribuições de pares utilizando as pontuações de compatibilidade euclidiana inversa em conjuntos de dados que contêm atributos numéricos e categóricos normalizados. A análise da Tabela 6 e da Figura 9 indica

que o GSM 10 tem uma pontuação média de 0,2894 com um desvio padrão baixo de 0,0172, o que sugere homogeneidade nas pontuações de compatibilidade. O GSM 10000 tem uma média de 0,2967 com um desvio padrão baixo de 0,0727, demonstrando consistência mesmo com grandes volumes de dados. Em contrapartida, o grupo gerado aleatoriamente teve uma média baixa de 0,0015 com um desvio padrão de 0,0087, indicando uma incompatibilidade quase total. O GSM 10000 demorou 146,5030 segundos para 12.848 iterações.

Tabela 6 - Dados do emparelhamento utilizando as pontuações de compatibilidade euclidiana inversa em conjuntos de dados numéricos e categóricos.

	média	mínimo	25%	mediana	75%	máximo	tempo de execução	iterações
GSM 10	0,2894	0,2592	0,2829	0,2953	0,3027	0,3070	0,0002	11
GSM 100	0,2930	0,0708	0,2815	0,2958	0,3318	0,4624	0,0122	125
GSM 1000	0,3003	0,0020	0,2829	0,3027	0,3413	0,4892	1,1398	1.280
GSM 10000	0,2967	0,0003	0,2792	0,3001	0,3381	0,4892	146,5030	12.848
Aleatório	0,0015	0,0001	0,0002	0,0003	0,0007	0,3574	0,0034	

Fonte: Pinheiro Junior (2024).

Comparando a Tabela 6 (dados mistos) com a Tabela 3 (dados apenas numéricos), nota-se uma diminuição das médias de compatibilidade quando são incluídos atributos categóricos. Apesar de menos iterações, o tempo de execução do GSM 10000 no conjunto de dados misto é ligeiramente inferior, o que sugere uma maior eficiência de processamento apesar da complexidade acrescida. A inclusão de atributos categóricos tem um impacto na avaliação da compatibilidade, resultando em pontuações mais baixas e numa variação de pontuação mais significativa.

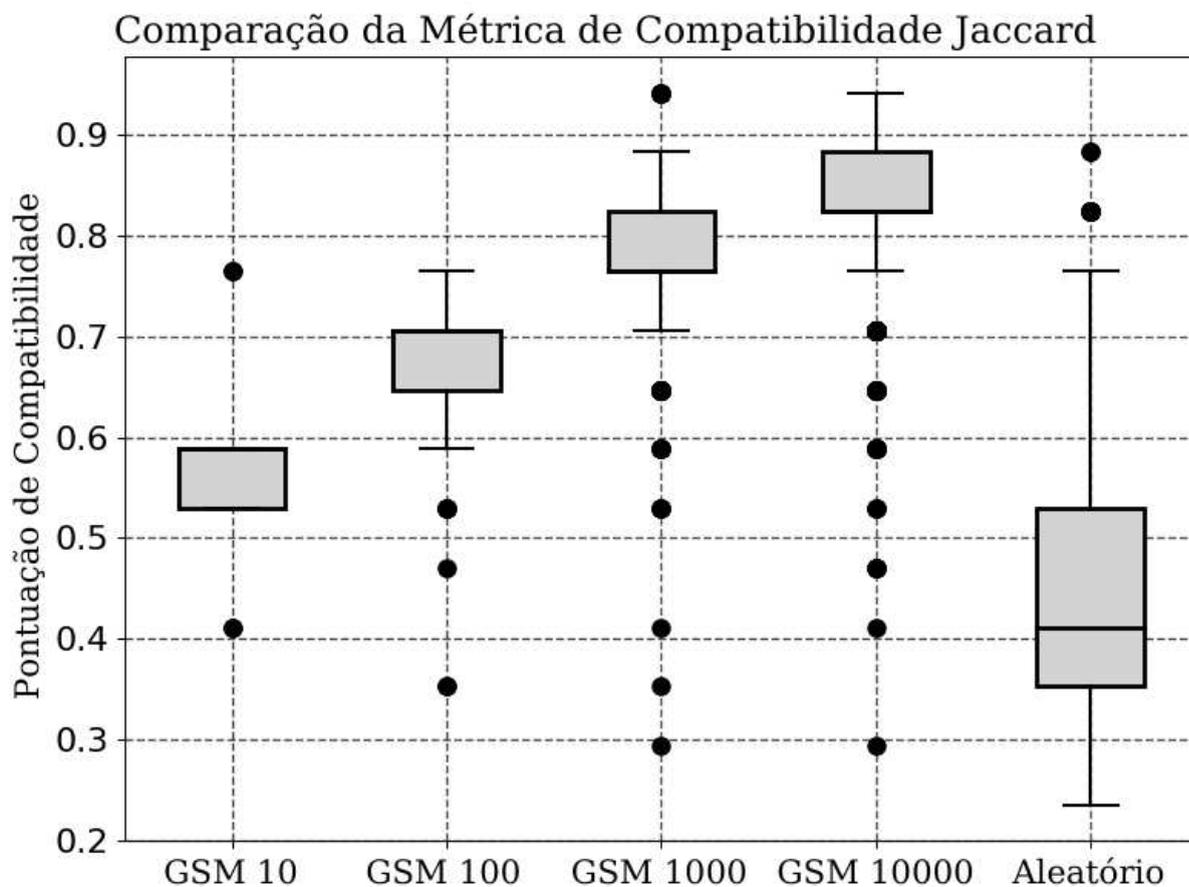


Figura 10 - Gráfico das distribuições de emparelhamento utilizando as pontuações de compatibilidade Jaccard em conjuntos de dados numéricos e categóricos.

Fonte: Pinheiro Junior (2024).

A Figura 10 mostra o diagrama de caixa das distribuições de pares utilizando as pontuações de compatibilidade do índice de Jaccard. Os resultados indicam uma melhoria significativa na qualidade do emparelhamento à medida que o tamanho do conjunto de dados aumenta, realçando a capacidade da métrica para identificar verdadeiras compatibilidades em um ambiente de dados mistos.

Tabela 7 - Dados de emparelhamento utilizando as pontuações de compatibilidade Jaccard inversa em conjuntos de dados numéricos e categóricos.

	média	mínimo	25%	mediana	75%	máximo	tempo de execução	iterações
GSM 10	0,5765	0,4118	0,5294	0,5882	0,5882	0,7647	0,0003	12
GSM 100	0,6865	0,3529	0,6471	0,7059	0,7059	0,7647	0,0265	122
GSM 1000	0,7799	0,2941	0,7647	0,7647	0,8235	0,9412	1,4173	1.241
GSM 10000	0,8414	0,2941	0,8235	0,8235	0,8824	0,9412	166,7902	12.063
Aleatório	0,4298	0,2353	0,3529	0,4118	0,5294	0,8824	0,0053	

Fonte: Pinheiro Junior (2024).

A Tabela 7 mostra que o GSM 10 tem uma pontuação média de compatibilidade de 0,5765 com um desvio padrão de 0,1141. O GSM 100 tem uma média de 0,6865 com um desvio padrão de 0,0802, e o GSM 1000 tem uma média de 0,7799 com um desvio padrão inferior de 0,0650. O GSM 10000 tem a pontuação média de compatibilidade mais elevada, de 0,8414, com o desvio padrão mais baixo de 0,0496. O grupo aleatório tem uma pontuação média de compatibilidade significativamente mais baixa, de 0,4298, com um desvio padrão de 0,1128. Os tempos de execução e as iterações aumentam com a dimensão do grupo, o que é comparável ao da Tabela 6.

A comparação da Tabela 7 (dados mistos) com a Tabela 4 (dados apenas numéricos) mostra médias mais elevadas, indicando que a inclusão de atributos categóricos aumenta a compatibilidade global. Ambas as tabelas apresentam resultados semelhantes relativamente ao tempo de execução e às iterações, com ligeiros aumentos no conjunto de dados mistos.

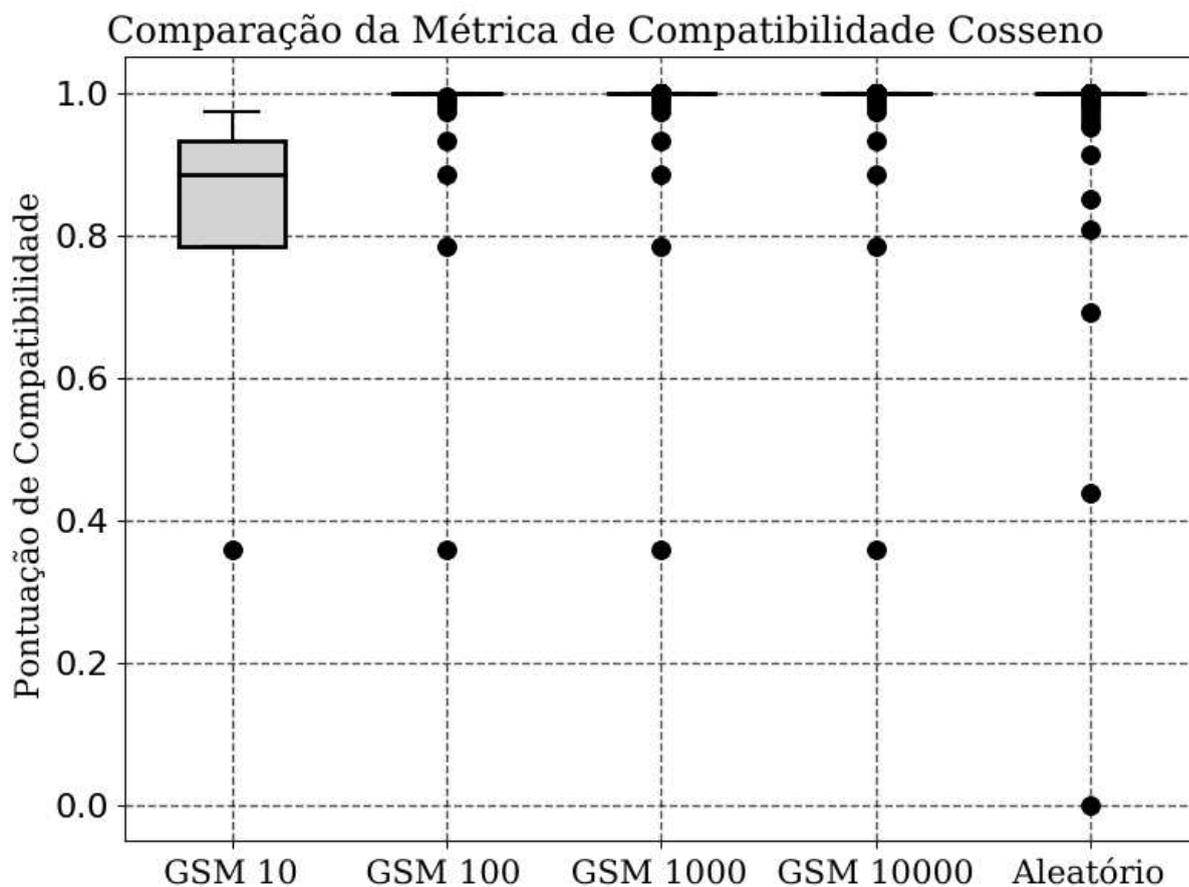


Figura 11 - Gráfico de distribuições de emparelhamento utilizando pontuações de compatibilidade Cosseno em conjuntos de dados numéricos e categóricos.

Fonte: Pinheiro Junior (2024).

A Figura 11 mostra o diagrama de caixa das distribuições de pares utilizando as pontuações de similaridade de cosseno. Os dados da Tabela 8 indicam a maior compatibilidade média com a métrica cosseno. No entanto, o elevado desempenho no modelo aleatório sugere que a natureza dos dados pode influenciar valores de compatibilidade elevados. A codificação *one-hot* para normalizar os dados categóricos introduz uma homogeneidade considerável e uma elevada dimensionalidade nos vectores, inflacionando potencialmente os valores de compatibilidade.

Tabela 8 - Dados de emparelhamento utilizando as pontuações de compatibilidade do cosseno inverso em conjuntos de dados numéricos e categóricos.

	média	mínimo	25%	mediana	75%	máximo	tempo de execução	iterações
GSM 10	0,7869	0,3589	0,7850	0,8855	0,9322	0,9728	0,0002	21
GSM 100	0,9774	0,3589	0,9987	0,9997	0,9999	1,0000	0,0152	200
GSM 1000	0,9977	0,3589	1,0000	1,0000	1,0000	1,0000	1,2249	1.607
GSM 10000	0,9998	0,3589	1,0000	1,0000	1,0000	1,0000	163,8606	15.479
Aleatório	0,9995	0,0005	1,0000	1,0000	1,0000	1,0000	0,0036	

Fonte: Pinheiro Junior (2024).

Em comparação com os emparelhamentos aleatórios, o algoritmo GSM melhora a estabilidade e a compatibilidade dos emparelhamentos nas três métricas (euclidiano inverso, Jaccard e cosseno). Para o euclidiano inverso e Jaccard, uma tendência clara de aumento da estabilidade e compatibilidade com valores de GSM mais elevados indica que o ajuste fino dos parâmetros do algoritmo pode melhorar significativamente a qualidade do emparelhamento. A métrica de similaridade Cosseno apresenta consistentemente pontuações de compatibilidade elevadas, demonstrando a sua robustez para o emparelhamento, mesmo com valores de GSM mais baixos, embora se verifiquem melhorias com definições de GSM mais elevadas.

O GSM 10000 produz consistentemente os pares mais estáveis e compatíveis em todas as métricas, sugerindo que é uma configuração para maximizar a estabilidade do emparelhamento. As pontuações consistentemente mais baixas e mais variáveis para pares aleatórios destacam a importância de usar um algoritmo estruturado para obter pares de alunos estáveis e compatíveis. Estes conhecimentos são essenciais para desenvolver e aplicar algoritmos para otimizar os pares de alunos para a aprendizagem colaborativa, garantindo que os pares formados são estáveis e altamente compatíveis.

A inclusão de características categóricas aumenta geralmente a variabilidade e introduz mais valores atípicos, mas o algoritmo GSM continua a melhorar a estabilidade e a compatibilidade dos pares em todas as métricas, em comparação com os pares aleatórios. A similaridade de cosseno fornece consistentemente a maior compatibilidade apenas para dados

numéricos, enquanto as métricas euclidiana inversa e Jaccard mostram melhorias significativas com valores de GSM mais altos.

A similaridade de Jaccard mostrou melhor desempenho com dados categóricos, pois é projetada para medir a similaridade entre conjuntos binários. Em contraste, a similaridade de cosseno, apesar de funcionar bem com dados numéricos, pode apresentar valores inflacionados quando aplicada a dados categóricos codificados em *one-hot*, devido à alta dimensionalidade resultante.

Quando características categóricas são adicionadas, todas as métricas mostram maior variabilidade, mas a eficácia do algoritmo GSM em melhorar a estabilidade e a compatibilidade permanece evidente. O GSM 10000 otimiza a estabilidade do emparelhamento em conjuntos de dados numéricos e numérico-categóricos combinados. Estes conhecimentos sublinham a importância da utilização de algoritmos estruturados para obter pares de alunos estáveis e compatíveis em contextos de aprendizagem colaborativa.

#### **4.1.5 Análise de emparelhamento: Variação do número de indivíduos.**

Esta secção examina como a qualidade dos emparelhamentos gerados pelo algoritmo de Gale-Shapley modificado se compara a um método de emparelhamento aleatório à medida que o número de indivíduos varia. Utilizamos medidas estatísticas como a média, o desvio padrão, os mínimos, os máximos, os quartis e o número de iterações necessárias para obter um emparelhamento estável para avaliar a qualidade do emparelhamento.

Os resultados mostram uma clara melhoria na qualidade do emparelhamento à medida que o tamanho do conjunto de dados aumenta de 10 para 10.000 indivíduos, medido pela compatibilidade média. O algoritmo de Gale-Shapley modificado forma pares de maior qualidade em média e mantém-se robusto e eficaz em diferentes escalas de dados sem comprometer a integridade do emparelhamento.

O desvio padrão das pontuações de compatibilidade aumenta com o tamanho do conjunto de dados, sugerindo uma maior diversidade na qualidade do emparelhamento em conjuntos de dados maiores. Apesar desta variação, o algoritmo continua a produzir

emparelhamentos de alta qualidade, como evidenciado pelos valores de compatibilidade máxima consistentemente elevados.

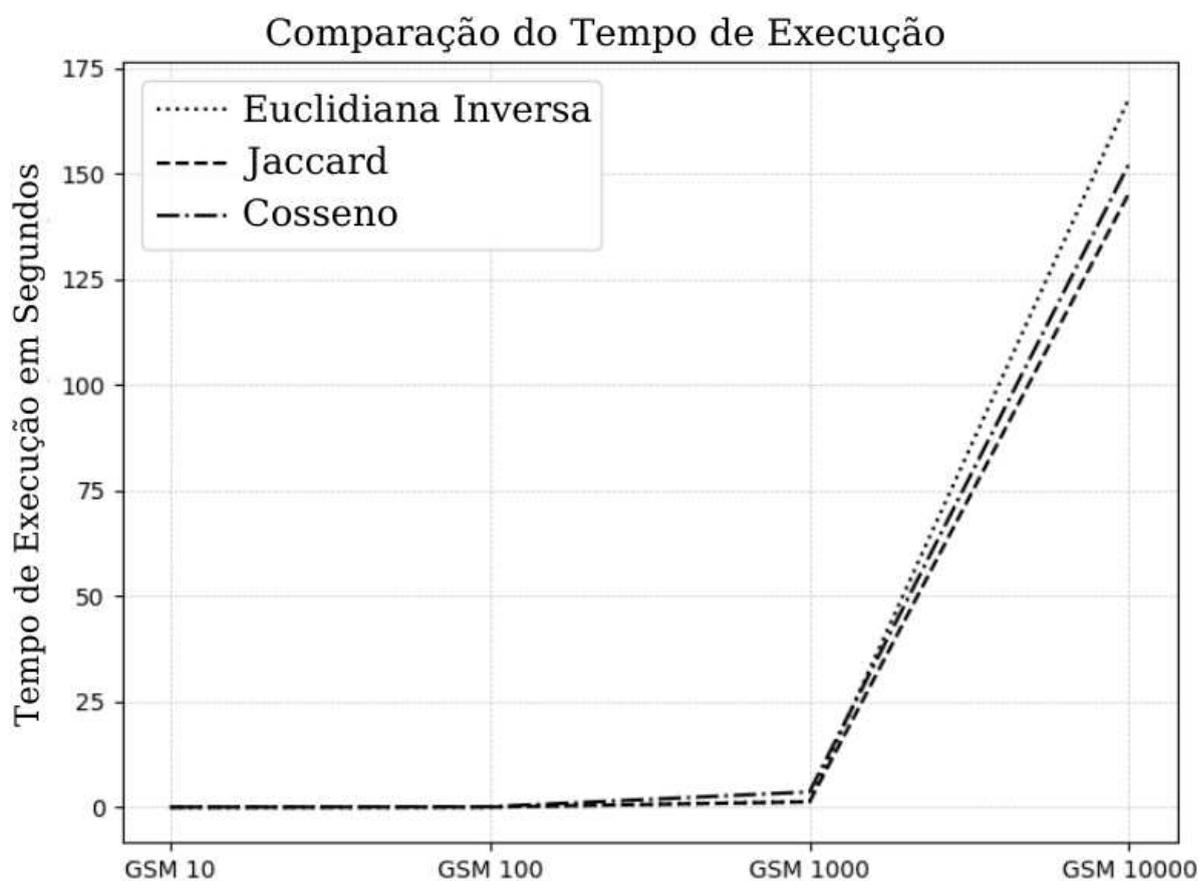


Figura 12 - Comparação do tempo de execução na formação de pares para as métricas de compatibilidade euclidiana inversa, Jaccard e cosseno. Fonte: Pinheiro Junior (2024).

O gráfico de comparação do tempo de execução (Figura 12) mostra o desempenho de três métricas de compatibilidade, Euclidiana Inversa, Jaccard e Cosseno, à medida que o tamanho do conjunto de dados aumenta. Os tempos de execução das três métricas aumentam gradualmente entre o GSM 10 e o GSM 1000, mas sobem acentuadamente após o GSM 1000, refletindo o aumento da procura computacional em escalas maiores. Embora a tendência geral seja semelhante em todas as métricas, o euclidiano inverso apresenta o aumento mais acentuado no tempo de execução, seguido de perto por Jaccard e Cosseno. Isto indica que, embora as três métricas escalem razoavelmente bem com conjuntos de dados mais pequenos, o seu desempenho diverge significativamente com conjuntos de dados maiores, realçando a importância de selecionar uma métrica adequada com base na dimensão do conjunto de dados e nas restrições computacionais. Apesar destes aumentos no tempo de execução, as métricas

continuam a ser viáveis para aplicações práticas que envolvam grandes conjuntos de dados, com compromissos a considerar entre a precisão e eficiência.

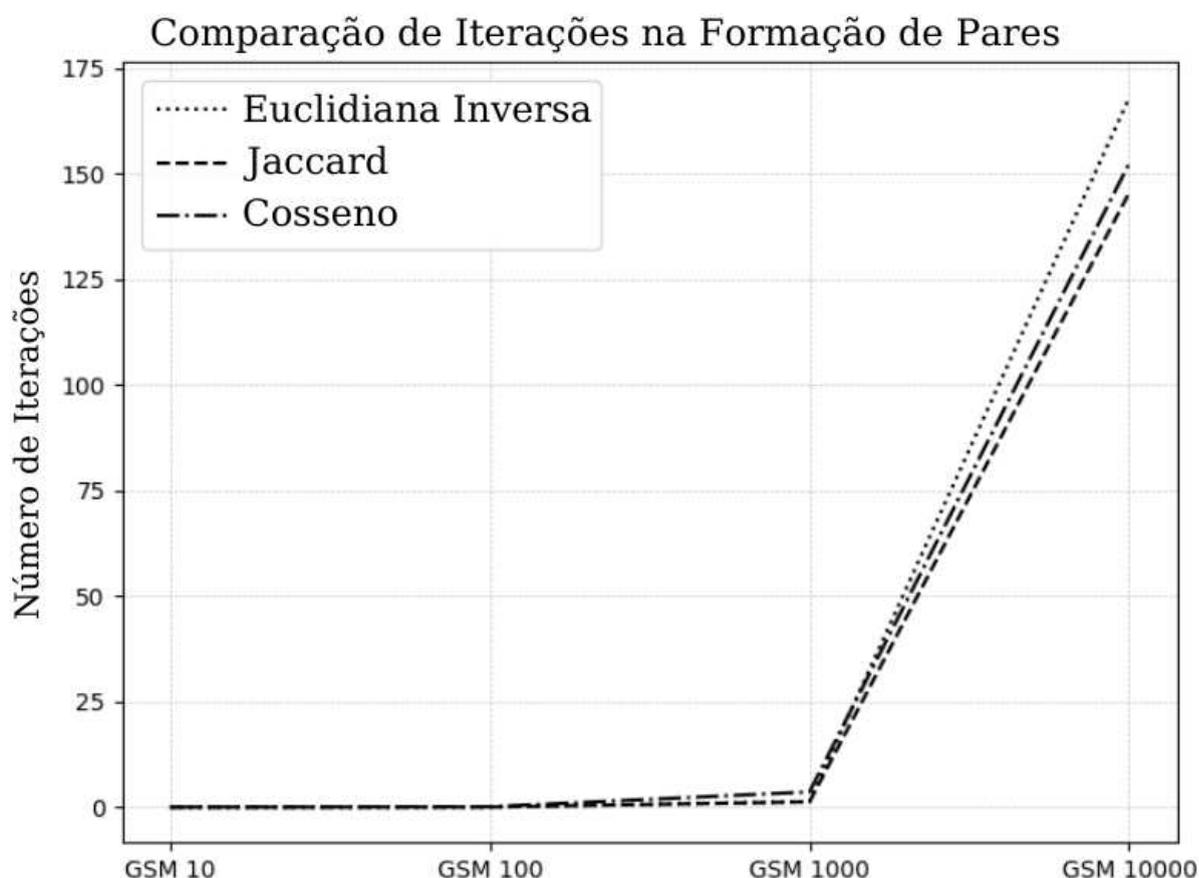


Figura 13 - Comparação de Iterações na Formação de Pares para as Métricas de Compatibilidade Euclidiana Inversa, Jaccard e Cosseno. Fonte: Pinheiro Junior (2024).

O gráfico de comparação de iterações (Figura 13) ilustra a forma como o número de iterações necessárias para o algoritmo de Gale-Shapley modificado varia consoante as três métricas de compatibilidade: Euclidiano Inverso, Jaccard e Cosseno. Tal como na análise do tempo de execução, o número de iterações permanece relativamente estável e baixo para conjuntos de dados mais pequenos (GSM 10 a GSM 100), com apenas um ligeiro aumento para GSM 1000. No entanto, após o GSM 1000, há um pico de iterações para as três métricas, particularmente para a Euclidiana Inversa, que requer o maior número de iterações, seguida de perto por Jaccard e cosseno. Este aumento de iterações com conjuntos de dados maiores indica que, embora o algoritmo seja eficiente para conjuntos de dados pequenos, o seu custo computacional aumenta rapidamente à medida que o conjunto de dados cresce, com cada métrica a apresentar um padrão de crescimento semelhante. Assim, essas questões devem ser

levadas em consideração, principalmente na escolha da métrica em aplicações de grande escala, onde a eficiência no número de iterações desempenha um papel crítico. Apesar deste aumento, o algoritmo continua a ser escalável, embora as diferenças de desempenho entre métricas se tornem mais pronunciadas com conjuntos de dados maiores.

Para lidar com conjuntos de dados massivos, uma possível abordagem é implementar o algoritmo utilizando processamento paralelo, distribuindo o cálculo das pontuações de compatibilidade em múltiplos núcleos ou máquinas. Alternativamente, pode-se aplicar uma etapa de clustering preliminar para reduzir o espaço de busca.

A análise do tempo de execução e do número de iterações fornece informações sobre a eficiência e a escalabilidade do algoritmo de Gale-Shapley modificado. Enquanto o tempo de execução aumenta significativamente com o tamanho do conjunto de dados, o número de iterações aumenta moderadamente. Estes resultados indicam que o algoritmo encontra eficientemente soluções estáveis mesmo em grandes conjuntos de dados, mostrando uma boa escalabilidade sem comprometer excessivamente a eficiência.

A análise demonstra que o algoritmo de Gale-Shapley modificado produz emparelhamentos de alta qualidade e adapta-se eficientemente a conjuntos de dados de dimensões variáveis. Mantém uma eficiência razoável em termos de tempo de execução e de iterações, mesmo com o aumento da escala dos dados, provando a sua aplicabilidade em vários contextos práticos em que a formação de pares com base em dados é fundamental.

#### **4.1.6 Otimização de Pares com Pares como Parâmetros e Avaliação da Eficiência do Algoritmo de Gale-Shapley Modificado**

O presente estudo avança a análise do algoritmo de Gale-Shapley modificado. Os resultados mostram que o algoritmo é eficaz e eficiente por si só, produzindo emparelhamentos que já operam em um nível ideal de compatibilidade. O escopo limitado para otimização identificado durante a pesquisa corrobora esse fato.

Observamos que a otimização aplicada aos pares resultou em um aumento marginal na pontuação geral de compatibilidade - uma melhoria de apenas 2,41 pontos. Esse resultado sutil reforça a noção de que o algoritmo de Gale-Shapley modificado, conforme

implementado, já maximiza a compatibilidade entre pares de uma maneira quase ideal no contexto de jogos educacionais digitais.

A melhoria modesta sugere que o potencial de otimização adicional é limitado, o que implica que a implementação inicial do algoritmo já está se aproximando do ponto de desempenho ideal. A análise gráfica da Figura 14 mostra que a distribuição das pontuações de compatibilidade após a otimização não é significativamente diferente da distribuição original. As medidas de tendência central e dispersão indicam que as diferenças são mínimas, portanto, a otimização não proporciona um benefício significativo.

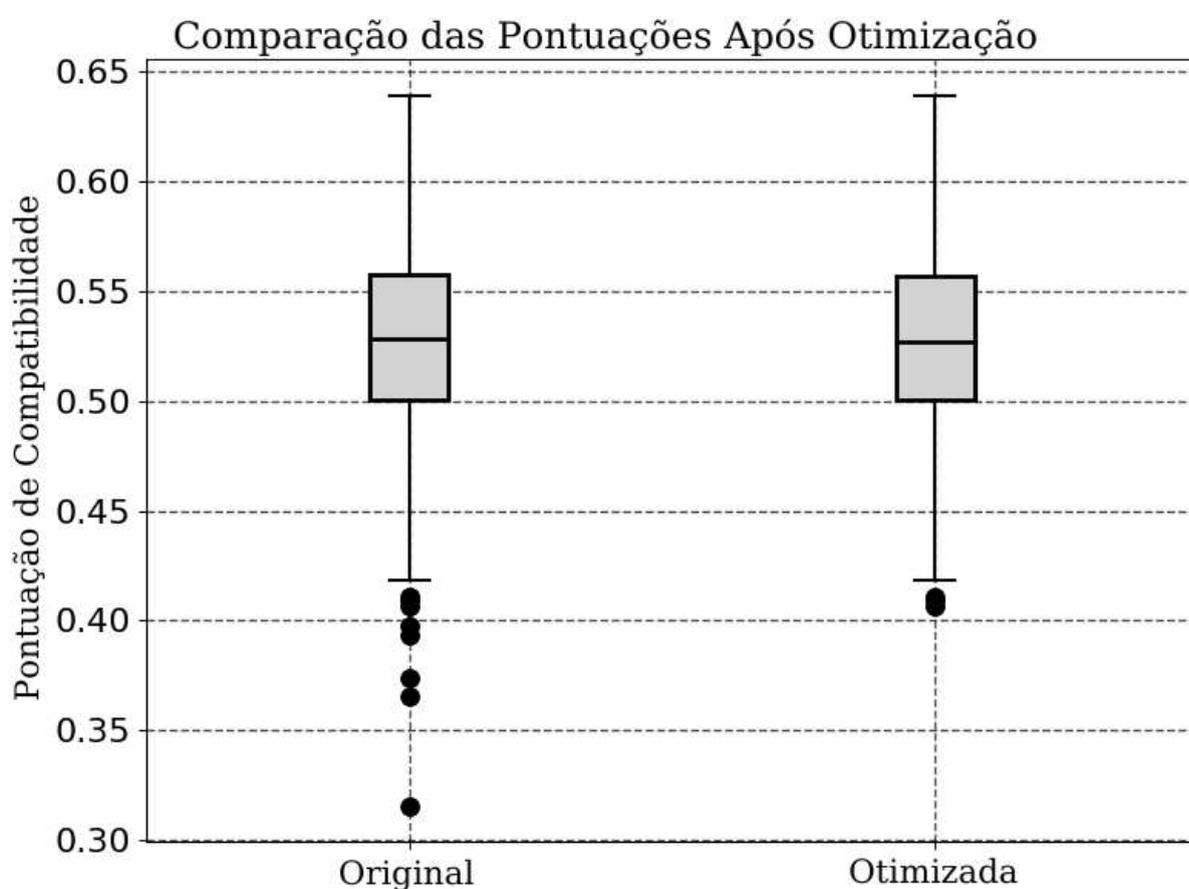


Figura 14 - Gráfico de Comparação das pontuações de compatibilidade após a otimização com a original. Fonte: Pinheiro Junior (2024).

As implicações dessa descoberta são duas. Primeiro, ela valida a eficácia do algoritmo de Gale-Shapley modificado em contextos educacionais em que a precisão na formação de pares é essencial para personalizar o aprendizado. Em segundo lugar, a descoberta ressalta a eficiência inerente do algoritmo, sugerindo que, em vez de buscar otimizações incrementais, o foco deve estar na aplicação e implementação corretas do próprio algoritmo.

Acredita-se que a melhoria marginal se deve ao fato de o algoritmo já estar próximo do ótimo global. Para explorar possibilidades adicionais de otimização, futuros estudos poderiam integrar métodos meta-heurísticos que permitam escapar de ótimos locais.

Em resumo, os resultados deste estudo indicam que o algoritmo de Gale-Shapley modificado é altamente eficaz em sua forma atual, deixando pouco espaço para melhorias adicionais por meio de otimização. Essa constatação não minimiza a importância da otimização em contextos apropriados, mas destaca a necessidade de reconhecer e valorizar a eficiência de algoritmos de pareamento bem projetados. O desafio futuro é aplicar e adaptar esses algoritmos robustos a contextos educacionais diversos e dinâmicos e continuar inovando e avançando em aplicações práticas na educação.

## **4.2 Resultados da Aplicação em Jogos Educacionais Competitivos**

### **4.2.1 Formação de pares**

O estudo teve como objetivo adaptar o algoritmo de Gale-Shapley para incorporar medidas de semelhança que calculam as pontuações de compatibilidade e avaliar a sua eficácia na formação de pares estáveis em contextos educativos e competitivos. Utilizando coeficientes de semelhança de Jaccard calculados a partir de testes de proficiência e desempenho acadêmico dos alunos, comparamos um grupo de controle emparelhado aleatoriamente com um grupo experimental emparelhado pelo algoritmo modificado.

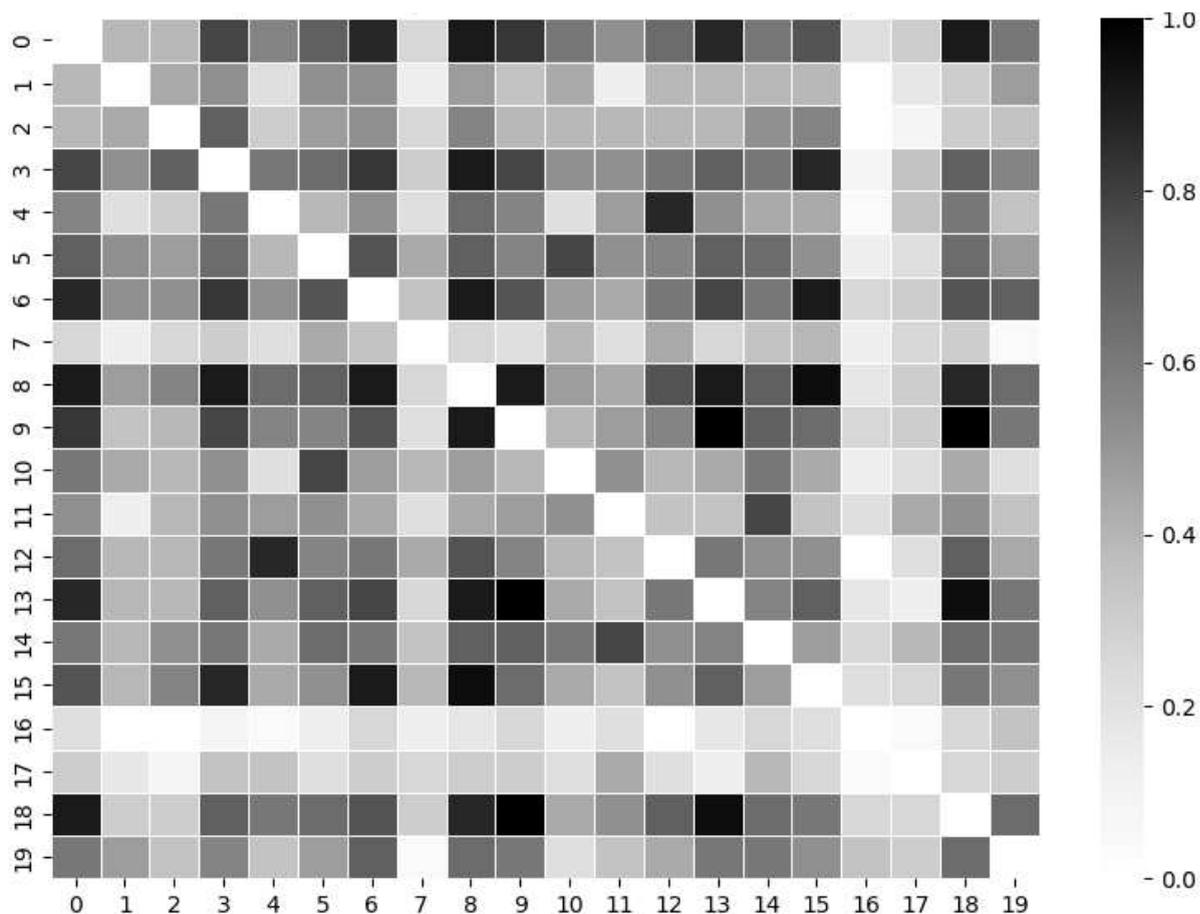


Figura 15 - Mapa de calor da compatibilidade entre alunos.

A Figura 15 apresenta um mapa de calor que ilustra as pontuações de compatibilidade entre 20 alunos, calculadas utilizando o coeficiente de semelhança de Jaccard. Cada célula do mapa representa a semelhança entre dois alunos específicos, com valores que variam de 0 (nenhuma semelhança) a 1 (semelhança total). As variações de cor nas células refletem diferentes níveis de compatibilidade: células mais escuras representam alta compatibilidade (valores próximos a 1), enquanto as mais claras indicam baixa compatibilidade (valores próximos a 0). Esta visualização ajuda-nos a identificar pares de alunos com níveis de proficiência e desempenho acadêmico semelhantes, o que é essencial para aplicar o algoritmo de Gale-Shapley modificado para formar pares educativos estáveis e eficazes.

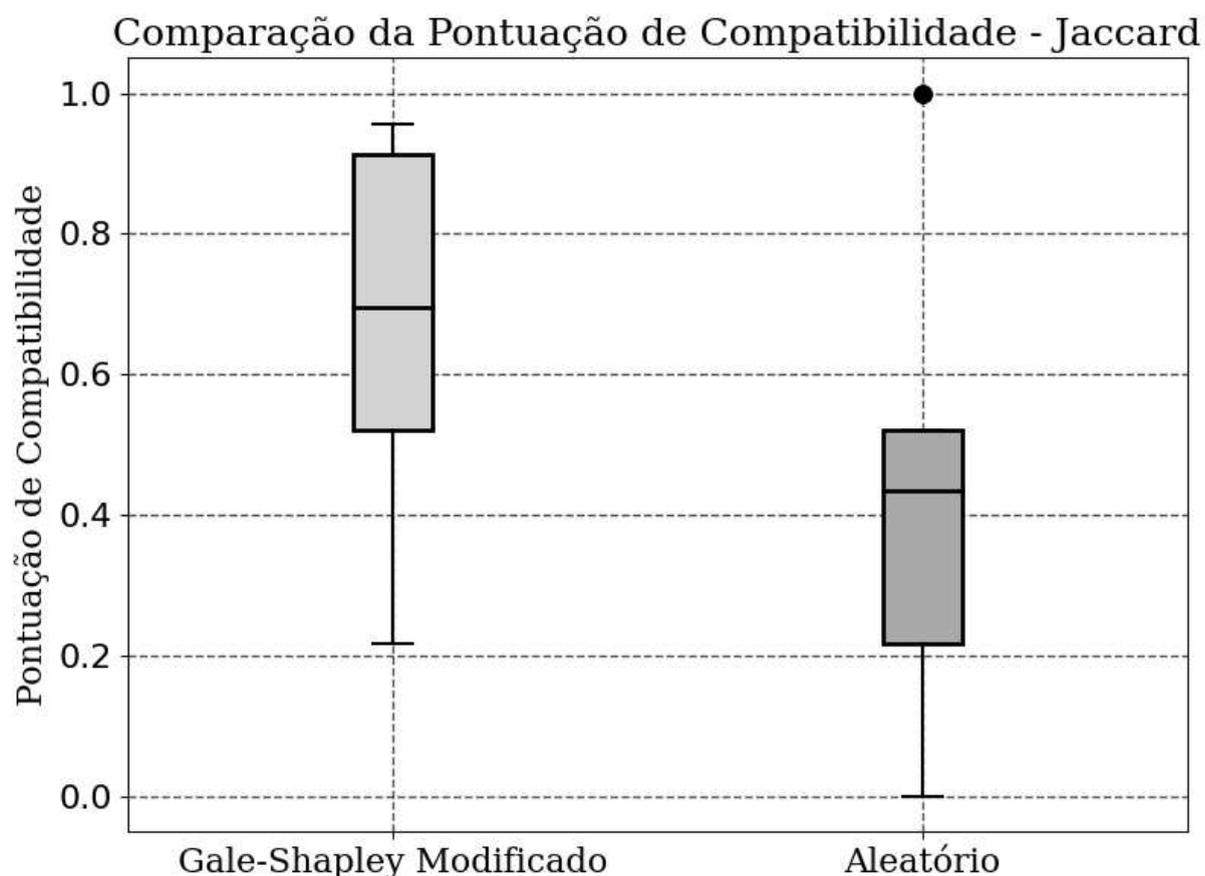


Figura 16 - Comparação das pontuações de compatibilidade.

A Figura 16 compara as pontuações de compatibilidade dos pares de alunos formados pelo algoritmo de Gale-Shapley modificado e pelo método de emparelhamento aleatório. O emparelhamento aleatório entre uma lista de indivíduos utiliza o módulo aleatório do NumPy. Para os pares formados pelo algoritmo de Gale-Shapley modificado, a pontuação de compatibilidade mediana é 0,6957, com uma média de 0,6609. O IQR vai de 0,5217 a 0,9130, indicando a dispersão das pontuações no segundo e terceiro quartis. Os valores mínimo e máximo são 0,2174 e 0,9565, respectivamente, com um desvio padrão de 0,2714. Relativamente aos pares formados aleatoriamente, a mediana do índice de compatibilidade é de 0,4348, com uma média de 0,4348. O IQR varia entre 0,2174 e 0,5217, indicando uma maior dispersão das pontuações em comparação com o método modificado. Os valores mínimo e máximo são 0,0 e 1,0, respectivamente, com um desvio padrão de 0,3357. Estes resultados indicam que o algoritmo de Gale-Shapley modificado tende a formar pares com maior compatibilidade e menor dispersão nas pontuações, sugerindo um emparelhamento mais consistente e equilibrado do que o método aleatório.

### 4.2.2 Comparação de desempenho

A Figura 17 mostra um gráfico de caixa que compara as diferenças de pontuação dos pares de alunos formados pelo algoritmo de Gale-Shapley modificado e o método de emparelhamento aleatório.

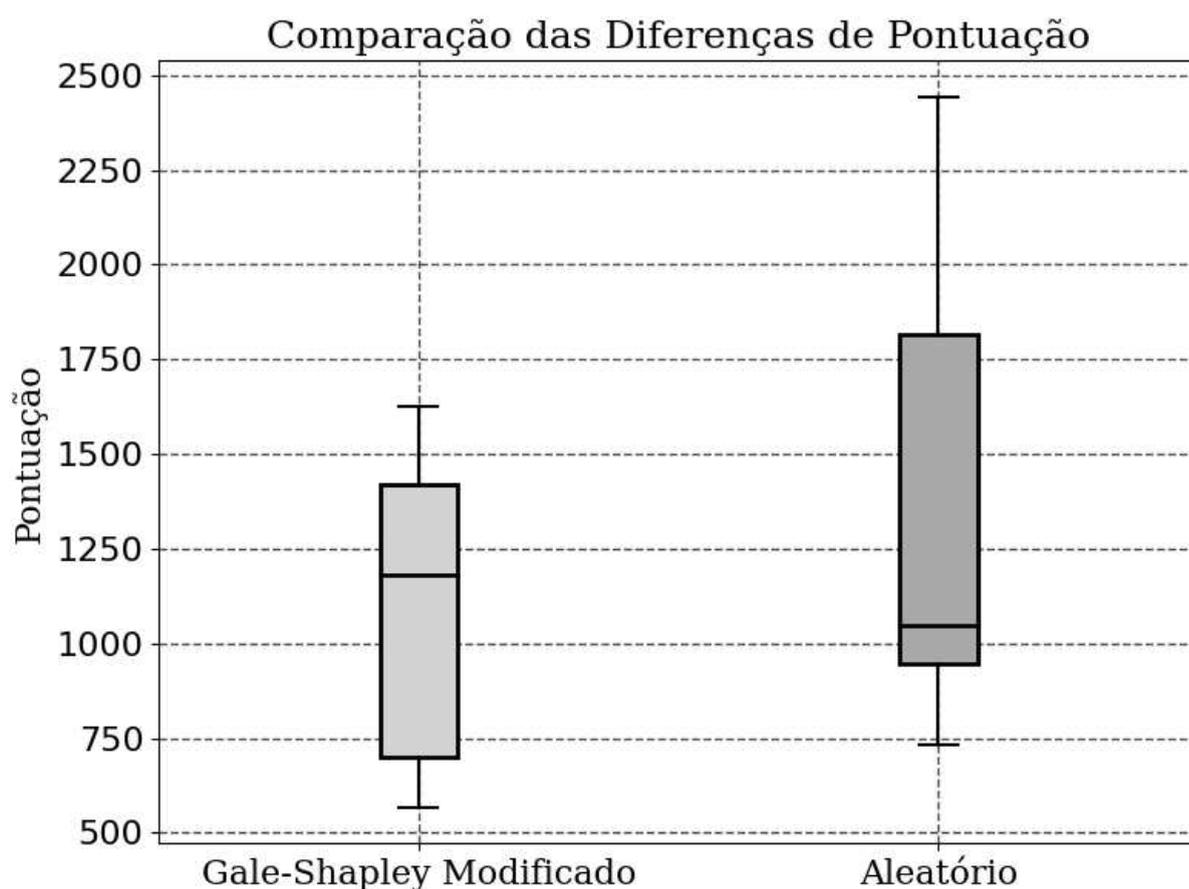


Figura 17 - Gráfico de caixa comparando as diferenças de pontuação de desempenho no jogo.

Na Figura 17, observa-se que os pares formados pelo algoritmo modificado apresentam uma diferença de pontuação menor, indicando um desempenho mais equilibrado entre os membros do par, o que sugere uma competição mais justa. A diferença de pontuação mediana para o algoritmo de Gale-Shapley modificado é de aproximadamente 1182, com um IQR de 698 a 1624. Os valores mínimo e máximo são 566 e 1624, respectivamente. A diferença de pontuação mediana para o método aleatório é de aproximadamente 1046, com um IQR de 732 a 1814 e valores mínimo e máximo de 732 e 2444, respectivamente.

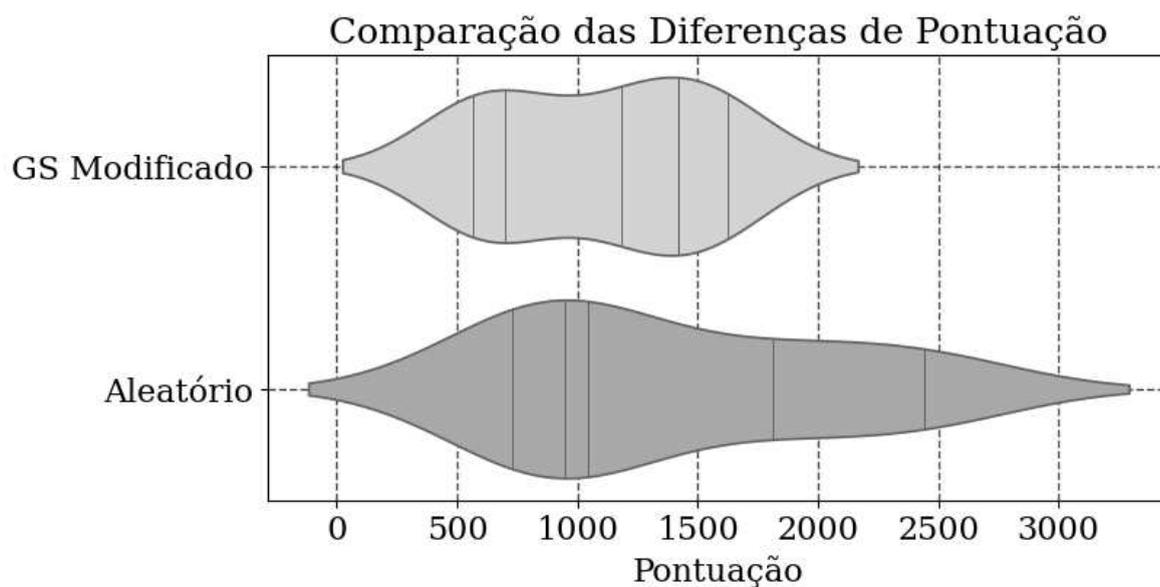


Figura 18 - Gráfico de violino da comparação das diferenças de pontuação de desempenho no jogo.

O gráfico de violino na Figura 18 fornece uma visão mais detalhada da distribuição das diferenças de pontuação, incluindo a densidade dos dados. Para o algoritmo de Gale-Shapley modificado, as diferenças de pontuação estão mais concentradas em torno da mediana de 1182, com uma distribuição relativamente simétrica e menos dispersa do que o método aleatório. Quanto ao processo aleatório, as diferenças de pontuação mostram uma distribuição mais dispersa, com uma variabilidade mais significativa e dois picos de densidade proeminentes em torno de 948 e 2444, indicando uma variação mais significativa nas diferenças de pontuação. Estes resultados sugerem que o algoritmo de Gale-Shapley modificado tende a produzir pares com diferenças de pontuação mais pequenas e menos dispersas, promovendo uma maior consistência no desempenho dos pares formados. Em contrapartida, o método aleatório revela uma variabilidade mais significativa nas diferenças de pontuação, sugerindo uma maior inconsistência no desempenho dos pares.

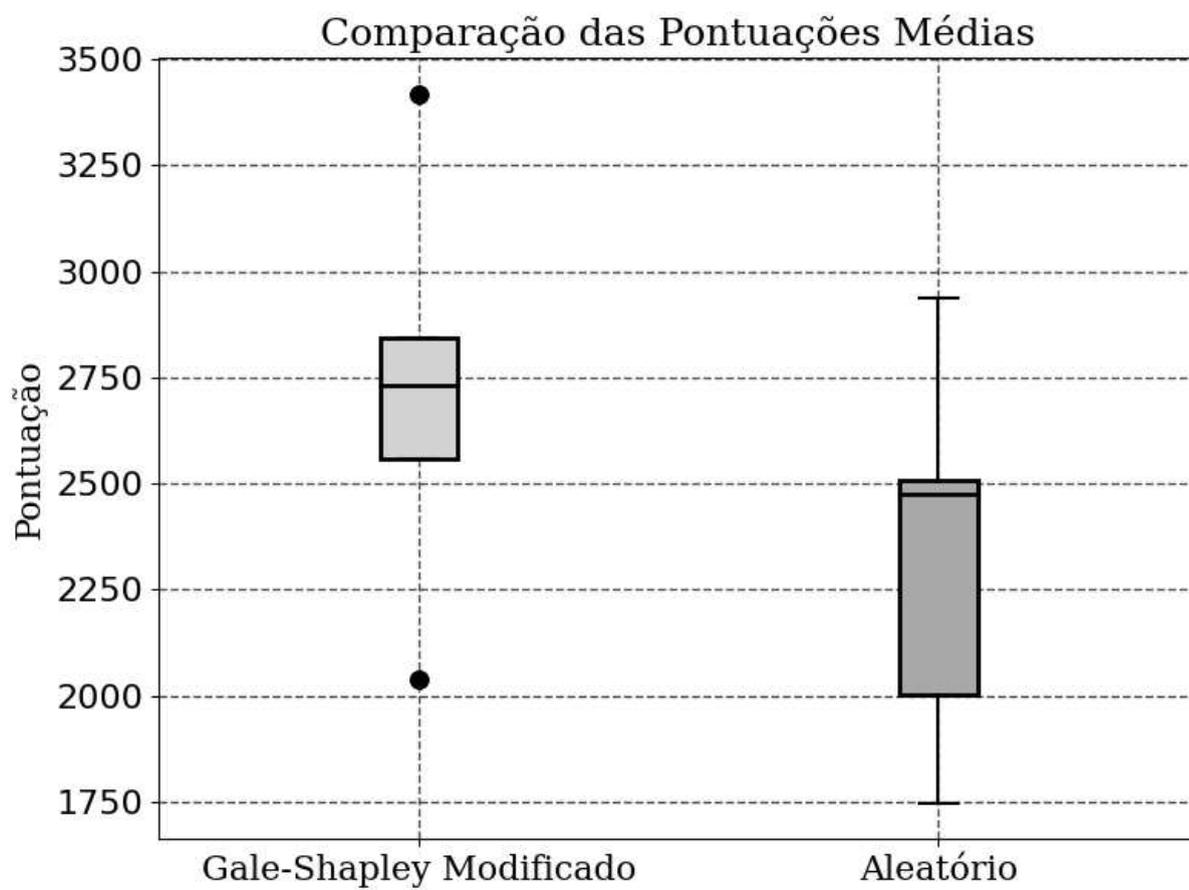


Figura 19 - Gráfico de caixa da comparação das pontuações médias de desempenho no jogo.

A Figura 19 revela que a pontuação média mediana para o algoritmo de Gale-Shapley modificado é de aproximadamente 2730, com um IQR que varia entre cerca de 2557 e 2843. Os valores mínimo e máximo são 2040 e 3419, respectivamente. Em comparação, a pontuação média mediana para o método aleatório é de aproximadamente 2474, com um IQR de cerca de 2003 a 2938. Os valores mínimo e máximo para o método aleatório são 1746 e 2938, respectivamente.

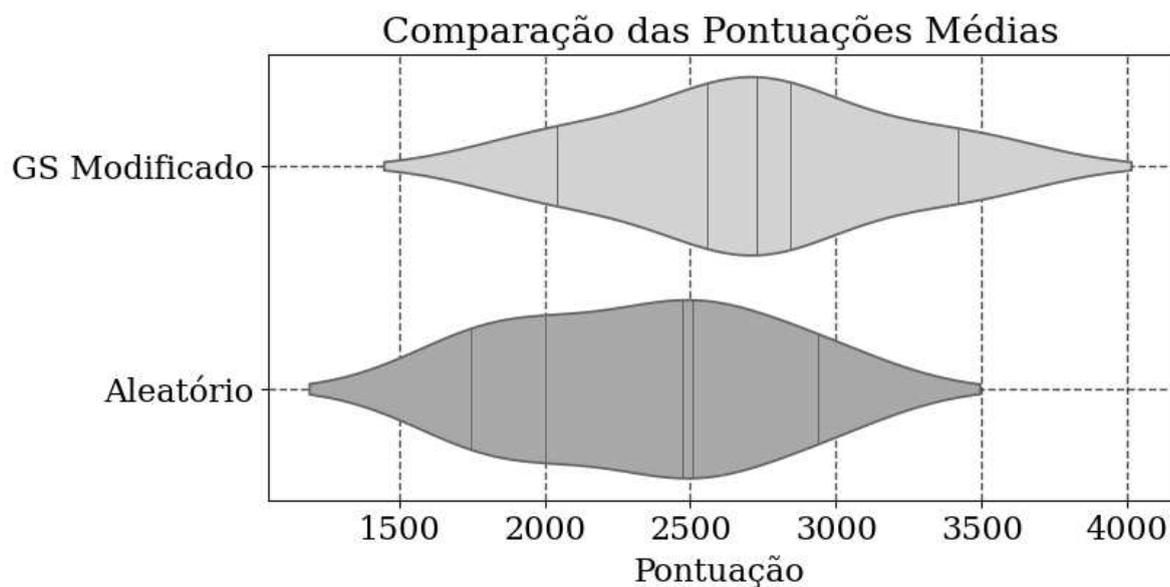


Figura 20 - Gráfico em violino da comparação das médias das pontuações de desempenho no jogo.

A Figura 20 ilustra a distribuição das médias de pontuação, incluindo a densidade dos dados. Para o algoritmo de Gale-Shapley modificado, as médias das pontuações estão mais concentradas em torno da mediana de 2730, apresentando uma distribuição relativamente simétrica e menos dispersa do que o método aleatório. Por outro lado, as pontuações médias do método aleatório mostram uma distribuição mais dispersa com uma variabilidade mais significativa. Dois picos de densidade proeminentes em torno de 2474 e 2938 indicam uma variação mais significativa nas pontuações médias. Estes resultados sugerem que o algoritmo de Gale-Shapley modificado produziu pares com médias de pontuação mais elevadas e menos dispersas, promovendo uma maior consistência no desempenho dos pares formados. Em contrapartida, o método aleatório revela uma variabilidade mais significativa nas pontuações médias, sugerindo uma maior inconsistência no desempenho dos pares.

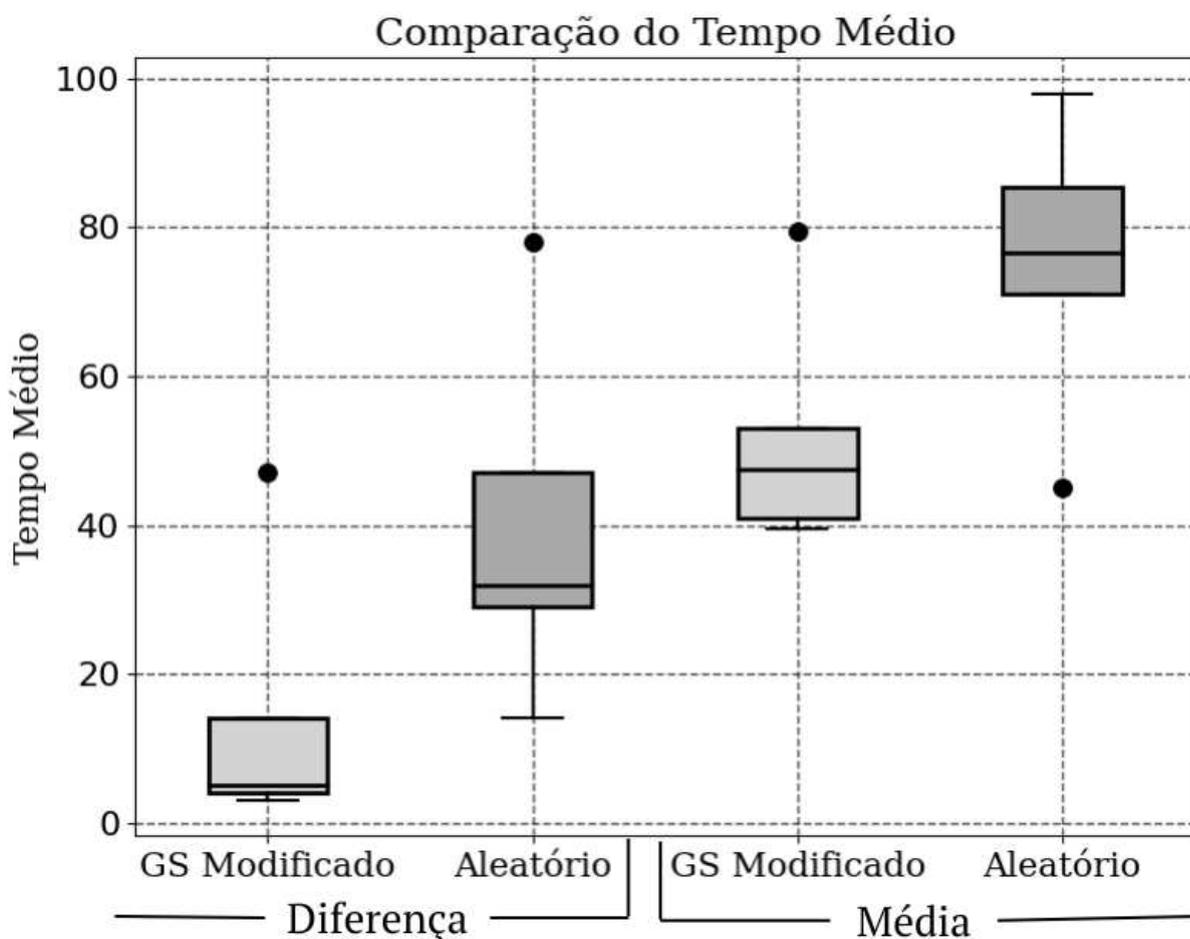


Figura 21 - Gráfico de caixa da Comparação do Tempo Médio por Resposta no Jogo.

Na Figura 21, o gráfico de caixa compara o tempo médio por resposta correta no jogo para o algoritmo de Gale-Shapley modificado e o método aleatório. O tempo médio por resposta do algoritmo modificado varia de aproximadamente 14 a 79,5 segundos, com uma mediana de cerca de 41 segundos e um IQR entre 39,5 e 53 segundos. Em comparação, o tempo médio de resposta do método aleatório varia de aproximadamente 14 a 98 segundos, com uma mediana de cerca de 76,5 segundos e um IQR de 45 a 85,5 segundos. Os valores discrepantes indicam uma variabilidade significativa nos tempos de resposta dos métodos, com o algoritmo modificado a apresentar tempos mais consistentes e mais curtos. Em comparação, o método aleatório apresenta uma dispersão mais excelente e tempos mais elevados.

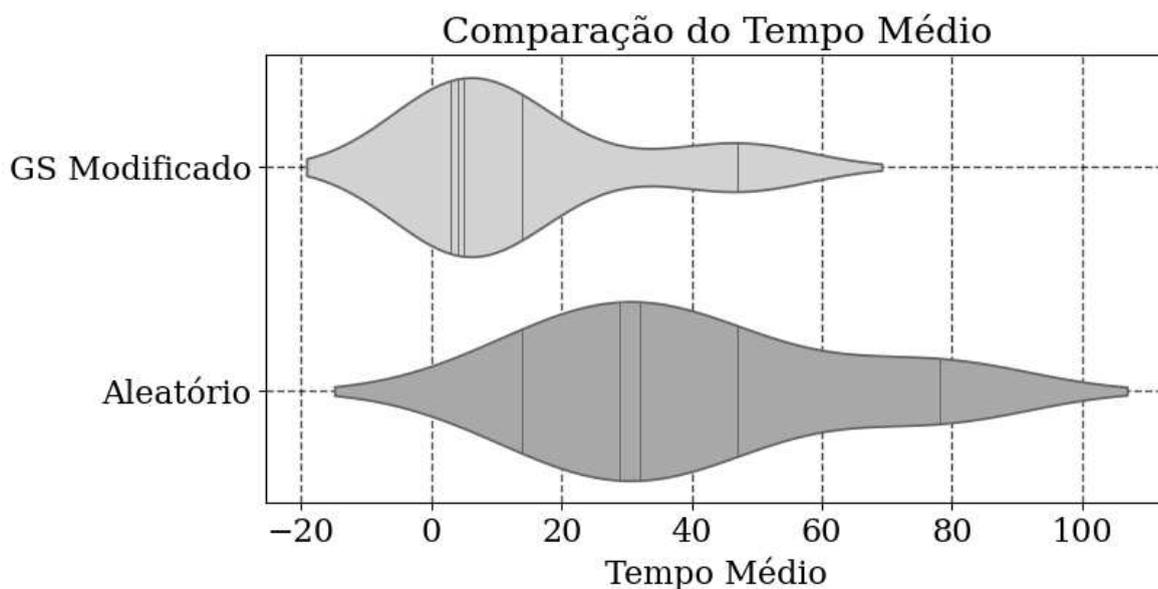


Figura 22 - Gráfico de violino comparando a diferença no tempo médio por resposta no jogo.

A Figura 22 ilustra a distribuição das diferenças no tempo médio de resposta, incluindo a densidade de dados. Para o algoritmo de Gale-Shapley modificado, as diferenças no tempo médio de resposta estão mais concentradas em torno de valores mais baixos, com uma distribuição relativamente simétrica e menos dispersa em comparação com o método aleatório. Por outro lado, as diferenças no tempo médio por resposta para o método aleatório apresentam uma distribuição mais alargada e dispersa, com maior variabilidade. Estes resultados sugerem que o algoritmo de Gale-Shapley modificado produz pares com tempos de resposta mais equilibrados e consistentes. Em contrapartida, o método aleatório revela uma variabilidade mais significativa nos tempos de resposta, sugerindo uma menor consistência no desempenho dos pares.

### 4.2.3 Análise qualitativa do *feedback* dos alunos

A análise abrange vários aspectos, incluindo o nível de envolvimento, a percepção da aprendizagem, a dificuldade dos desafios, a motivação para resolver os desafios e a contribuição do formato do jogo para a aprendizagem.

#### 4.2.3.1 Nível de engajamento

Contagem de Como você classificaria seu nível de engajamento durante o jogo?

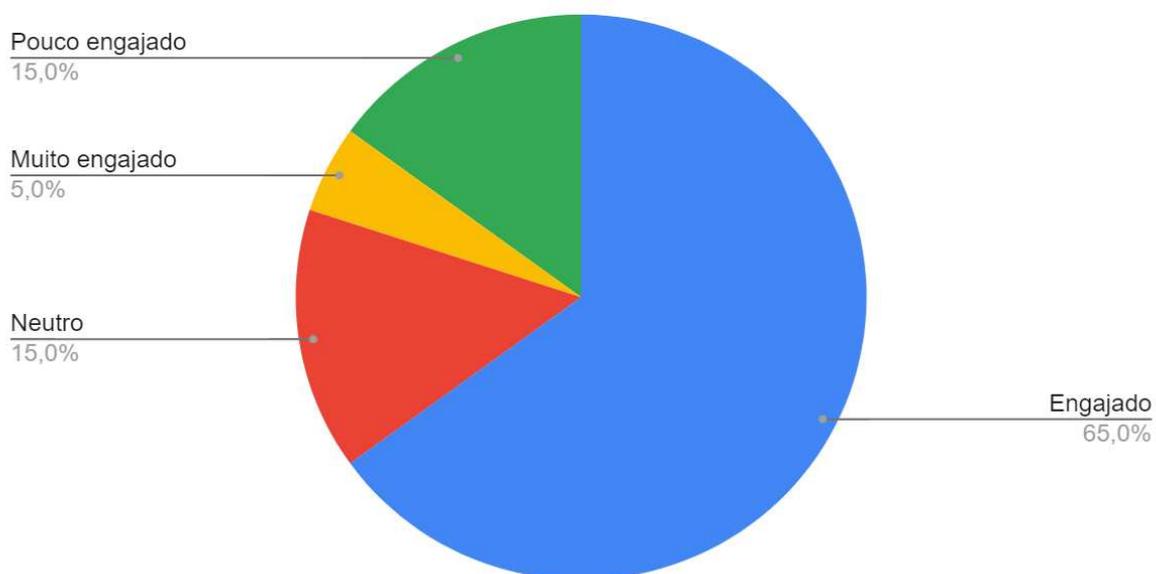


Figura 23 - Gráfico do nível de engajamento dos estudantes durante o jogo.

A maioria dos alunos declarou estar “engajado”, com 13 indivíduos nesta categoria. Três alunos declararam-se “neutros”, enquanto outros três se mostraram “pouco engajados”. Apenas um aluno referiu estar “Muito engajado”.

#### 4.2.3.2 Percepção da aprendizagem

Todos os participantes afirmaram que o jogo ajudou a sua aprendizagem, demonstrando um impacto globalmente positivo do jogo educativo.

#### 4.2.3.3 Dificuldade do jogo

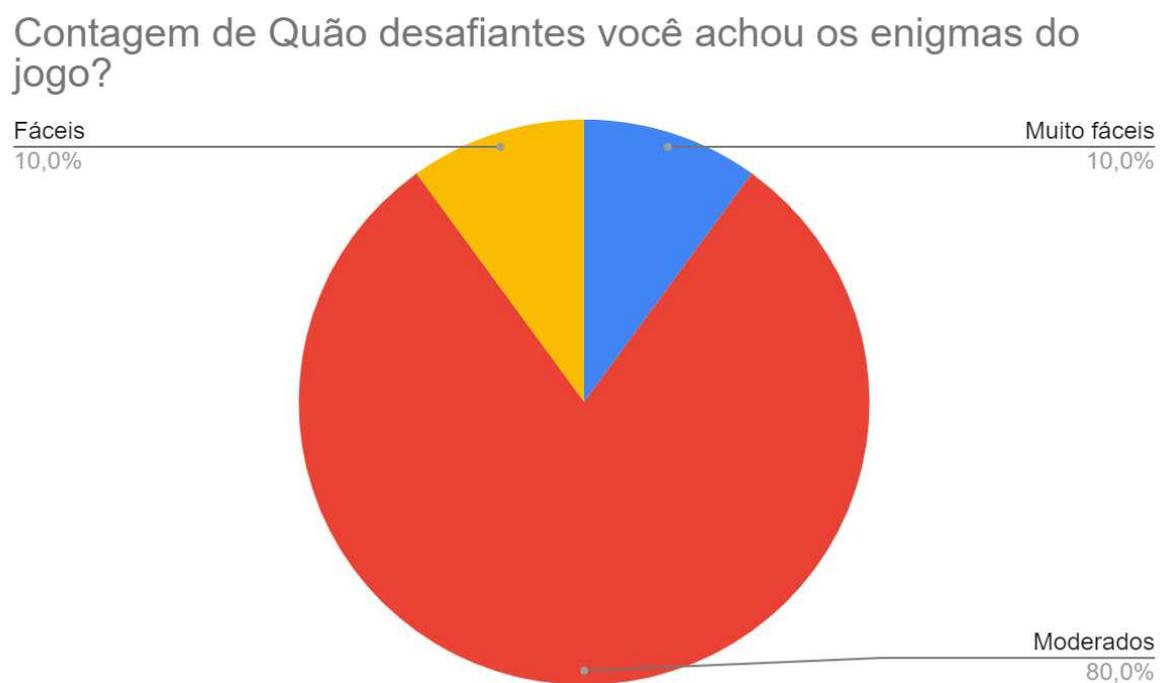


Figura 24 - Gráfico do nível de desafio do jogo.

A maioria dos participantes considerou o desafio “moderados”, totalizando 16 respostas. Dois indivíduos consideraram 'Muito fáceis' e dois consideraram-nos 'Fáceis'.

#### 4.2.3.4 Motivação para resolver os desafios

Contagem de Você se sentiu motivado a resolver os desafios do jogo?

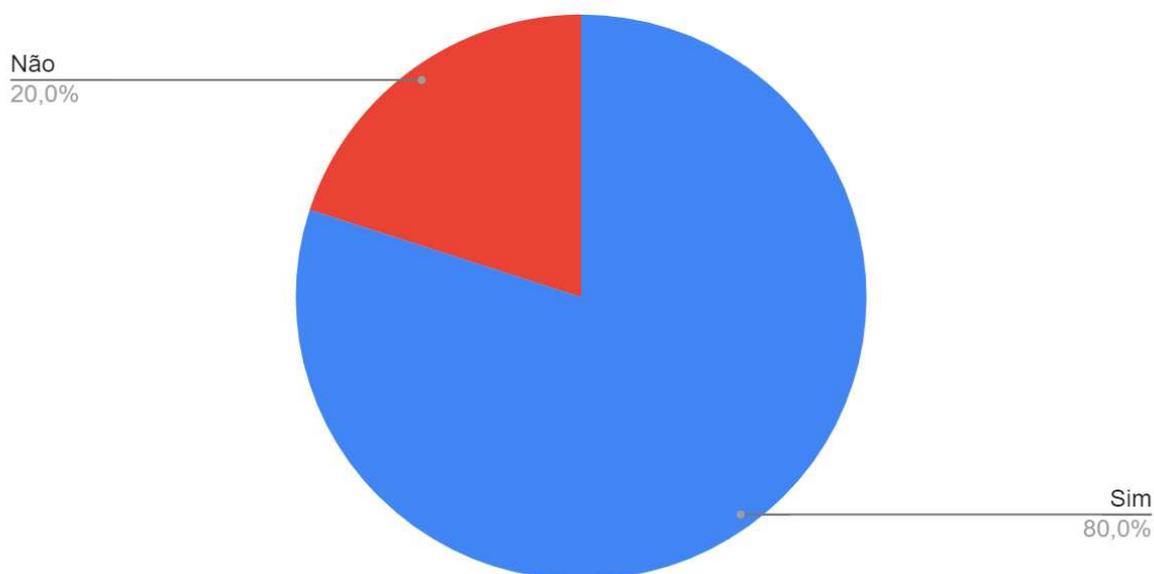


Figura 25 - Gráfico de motivação dos estudantes.

A maioria dos alunos (16) sentiu-se motivada para resolver os desafios do jogo. Quatro alunos sentiram que precisavam de mais motivação, o que pode indicar a necessidade de ajustes para manter o interesse de todos os jogadores.

#### 4.2.3.5 Contribuição do formato para a aprendizagem

A maioria dos participantes (18) sentiu que o formato do jogo contribuiu para a aprendizagem. Dois participantes não sentiram esse contributo, o que pode indicar preferências individuais ou limitações na concepção do jogo.

#### 4.2.3.6 Avaliação da Dinâmica e do Jogo Educativo

Contagem de Como você avalia a dinâmica e jogo educativo em termos de melhorar seu aprendizado?

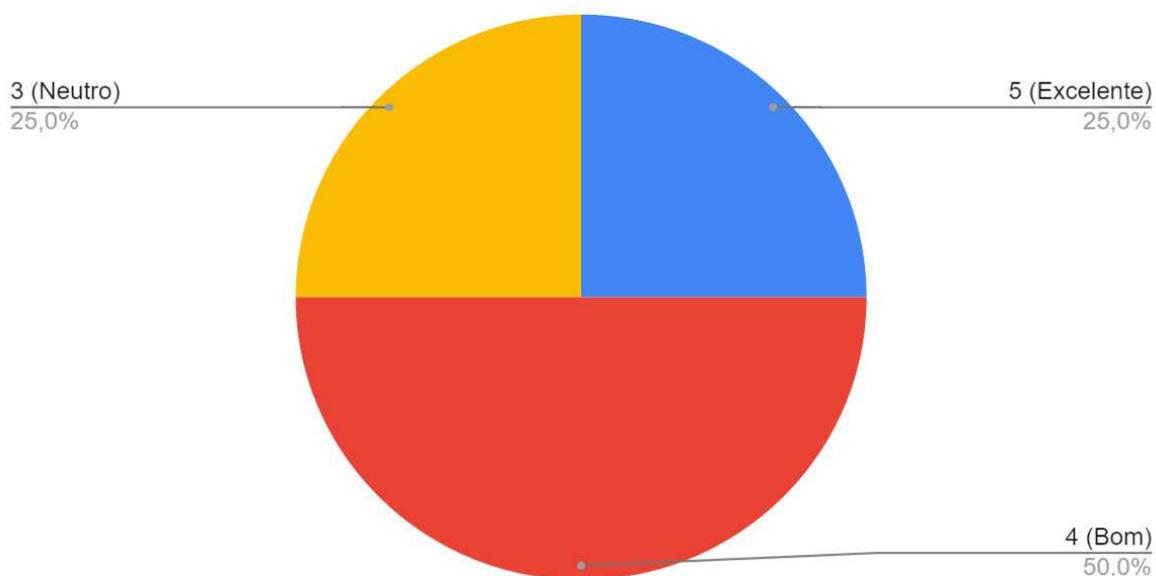


Figura 26 - Gráfico de avaliação dos estudantes sobre a dinâmica e jogo educativo em termos de melhora do aprendizado.

Globalmente, a avaliação do impacto do jogo na aprendizagem foi maioritariamente positiva: Cinco alunos atribuíram-lhe a pontuação máxima de “5 (Excelente)”. Dez participantes classificaram-no como “4 (Bom)”. Cinco alunos atribuíram-lhe notas mais neutras, com '3 (Neutro)!'.

A análise mostra que o jogo educativo foi bem recebido pela maioria dos alunos, com destaque para a aprendizagem promovida e o envolvimento gerado. No entanto, são necessárias mais melhorias no que se refere a manter a motivação dos alunos e a aperfeiçoar a dificuldade dos puzzles para melhor se adaptarem às diversas capacidades e preferências dos alunos.

Estes dados sugerem que o jogo tem um bom potencial como ferramenta educativa, mas o seu aperfeiçoamento poderia aumentar ainda mais a sua eficácia e o seu envolvimento. Continuar a recolher *feedback* e a adaptar o conteúdo de acordo com as necessidades dos alunos será fundamental para o sucesso contínuo do jogo educativo.

#### 4.2.4 Interpretação dos resultados

A análise quantitativa dos participantes revelou que o algoritmo modificado apresentou uma gama de pontuações médias de 2040 a 3419, com uma média de 2717,8 e um desvio padrão médio de 549. Em contraste, o emparelhamento aleatório apresentou um intervalo de 1746 a 2938, uma média de 2333,6 e um desvio padrão médio de 698,4. Relativamente à diferença de pontuação, o algoritmo modificado variou de 566 a 1624, enquanto o emparelhamento aleatório variou de 732 a 2444. O desvio-padrão da pontuação foi de 283 a 812 para o algoritmo modificado e de 366 a 1222 para o emparelhamento aleatório.

Na análise comparativa, observamos que o método modificado produziu uma pontuação média mais elevada (2717,8) do que o método aleatório (2333,6), com um desvio padrão mais baixo, indicando uma maior consistência nos resultados. No entanto, a contagem de respostas erradas foi mais elevada com o método modificado, mas apresentou menor variação, indicando que, embora os alunos tenham tentado mais respostas, mantiveram a exatidão. O tempo médio de resposta foi menor para o método modificado (52,7 segundos) do que para o método aleatório (75,2 segundos), sugerindo que os alunos emparelhados com o método modificado responderam rapidamente. Finalmente, a diferença no tempo total de jogo foi menor para o método modificado, indicando maior eficiência para os pares formados por este método.

A interpretação dos resultados evidencia que o algoritmo de Gale-Shapley modificado tende a criar pares com um desempenho mais equilibrado em termos de respostas corretas e incorretas. Os pares modificados apresentaram respostas corretas mais consistentes, variando entre 32 e 56, e respostas incorretas geralmente mais baixas, indicando um melhor desempenho coletivo. Por outro lado, os pares aleatórios apresentaram uma variação mais significativa nas respostas corretas e incorretas, com alguns pares a atingirem até 57 respostas corretas e outros apenas 15, e as respostas incorrectas a variarem significativamente.

# Capítulo 5

## Discussão

### 5.1 Interpretação dos Resultados da Simulação SEL

A análise dos resultados obtidos pela aplicação do algoritmo modificado de Gale-Shapley em SEL revelou *insights* sobre a eficácia da metodologia proposta. Ao utilizar métricas de compatibilidade como distância euclidiana inversa, similaridade de Jaccard e similaridade de cosseno, foi possível observar diferentes níveis de eficiência na formação de pares.

A similaridade de cosseno, em particular, demonstrou maior eficácia na formação de pares com alta compatibilidade, o que resultou em grupos de melhor desempenho em termos de colaboração. Esses resultados corroboram com a literatura existente, que sugere que métricas baseadas em vetores (como a similaridade de cosseno) são especialmente eficazes em cenários de aprendizado colaborativo e competitivo. No entanto, essa métrica gerou alguns problemas quando utilizada com atributos categóricos com método de normalização de codificação *one-hot*. Além disso, o tempo de execução mais elevado associado à similaridade de cosseno indica que, em ambientes com grande volume de dados, é necessário considerar um equilíbrio entre qualidade e custo computacional.

Por outro lado, a aplicação da similaridade de Jaccard, mais eficiente em termos de processamento, pode ser ideal em cenários onde a diversidade de atributos categóricos (como estilos de aprendizado e preferências) é predominante. Essa flexibilidade nas métricas de compatibilidade destaca a importância do pré-processamento adequado dos dados para maximizar a precisão nas correspondências, como evidenciado pelos resultados normalizados por meio do SDV.

## **5.2 Interpretação dos Resultados da Aplicação em Jogos Digitais Educacionais Competitivos**

A modificação do algoritmo de Gale-Shapley para ambientes educacionais competitivos provou ser eficaz na formação de pares equilibrados, garantindo estabilidade e otimização das interações entre os alunos. Nossos dados mostram que a menor variabilidade no desempenho entre os pares formados resultou em competições mais justas, com maior homogeneidade nas pontuações e maior envolvimento dos participantes. Estudos prévios já indicam que uma competição bem estruturada pode aumentar a motivação e o desempenho acadêmico, o que é consistente com os resultados observados.

### **5.2.1 Implicações para a competitividade e o envolvimento**

Os resultados sugerem que a utilização do algoritmo de Gale-Shapley modificado para a geração de pares em jogos digitais educativos pode melhorar a competitividade entre os participantes. A consistência no desempenho, as pontuações médias mais elevadas e o desvio padrão mais baixo indicam que os pares formados são mais compatíveis e têm um desempenho mais homogêneo, o que pode levar a uma competição mais justa e mais envolvente.

Estudos anteriores (Vlachopoulos e Makri, 2017; Laine e Lindberg, 2020) sublinham que a competição estruturada nos jogos educativos aumenta a motivação dos alunos e melhora os resultados da aprendizagem. Os nossos resultados são consistentes com este fato, mostrando que a menor variação nas pontuações entre pares formados pelo algoritmo de Gale-Shapley modificado indica um ambiente de aprendizagem mais equilibrado e competitivo. Observamos que uma competição bem estruturada nos jogos educativos proporciona desafios adequados aos alunos, aumentando o seu envolvimento. Na nossa investigação, a utilização do algoritmo modificado resultou em pares mais compatíveis e numa competição mais justa, como evidenciado pela menor dispersão das pontuações (Figuras 17, 18). Isto sugere que a competição saudável promovida pelos pares compatíveis incentiva os alunos a esforçarem-se mais e a envolverem-se mais nas atividades.

## **5.2.2 Satisfação e motivação dos participantes**

A literatura educacional sugere que a satisfação pode aumentar a motivação e o engajamento dos alunos (Johnson e Johnson, 1999; Slavin, 1996). O fato de a maioria dos alunos se ter mostrado empenhada ou muito empenhada durante a atividade sugere que o emparelhamento equilibrado contribui para um ambiente de aprendizagem mais motivador.

A formação de pares equilibrados utilizando algoritmos como o de Gale-Shapley modificado pode melhorar a colaboração e a aprendizagem dos alunos. A literatura sugere que uma competitividade saudável pode aumentar o engajamento e a motivação dos alunos, melhorando a aprendizagem (Csikszentmihalyi, 2009; Deci, 1985). Além disso, a utilização de jogos digitais bem concebidos, como o 'Labirinto da Educação', pode efetivamente envolver os alunos e melhorar a aprendizagem por meio de desafios moderados e *feedback* imediato (Gee, 2007; Prensky, 2001).

Os resultados deste estudo mostram que os pares formados pelo algoritmo de Gale-Shapley modificado apresentaram uma maior compatibilidade e um desempenho mais consistente do que os pares formados aleatoriamente. A integração do algoritmo de Gale-Shapley com as tecnologias educativas pode criar ambientes de aprendizagem mais eficazes e envolventes, aumentando a compatibilidade e a satisfação dos alunos com os seus parceiros de estudo e resultando em melhores resultados de aprendizagem. Recomenda-se a implementação do algoritmo de Gale-Shapley modificado em contextos educativos em que a formação de pares equilibrados e eficazes é essencial para o sucesso da aprendizagem colaborativa e competitiva.

## **5.2.3 Recomendações práticas**

### **5.2.3.1 Implementação de algoritmos de emparelhamento**

Os educadores podem considerar a utilização do algoritmo de Gale-Shapley modificado para formar pares em atividades de colaboração e competição. Isto pode ser útil em salas de aula onde um equilíbrio de competências contribui para o sucesso da aprendizagem em colaboração.

**Exemplo prático:** Numa aula de inglês, os educadores podem utilizar o algoritmo para formar pares para projetos de leitura ou escrita. Isto garante que os alunos são emparelhados com colegas de níveis de proficiência semelhantes, o que pode melhorar a colaboração e a aprendizagem.

**Exemplo prático:** Educadores podem utilizar plataformas como o Moodle ou sistemas personalizados que integrem o algoritmo de Gale-Shapley modificado para formar grupos em atividades colaborativas, garantindo compatibilidade entre os alunos.

### 5.2.3.2 Utilização de jogos didáticos

Os jogos digitais, como o “Labirinto da Educação”, podem ser integrados no currículo para tornar a aprendizagem mais interactiva e cativante. Certifique-se de que os jogos que escolher têm *feedback* imediato e níveis de dificuldade variáveis para manter os alunos desafiados sem os sobrecarregar.

**Exemplo prático:** Durante uma aula sobre gramática inglesa, o 'Labirinto da Educação' pode reforçar conceitos por meio de desafios e puzzles que requerem a aplicação prática das regras gramaticais aprendidas.

### 5.2.3.3 Design de jogos personalizados

Os criadores devem considerar a incorporação de algoritmos de emparelhamento, como o Gale-Shapley, nos seus jogos para melhorar a formação de pares e grupos. A incorporação destes algoritmos pode aumentar a eficácia da aprendizagem, garantindo que os jogadores são compatíveis em termos de competências e conhecimentos.

**Exemplo prático:** Um jogo de matemática pode incluir um sistema de emparelhamento que utilize algoritmos para formar pares de alunos com competências e conhecimentos complementares.

#### 5.2.3.4 *Feedback* e ajuste da dificuldade

Os jogos educativos devem fornecer *feedback* imediato e ajustar a dificuldade das tarefas com base no desempenho dos jogadores. O fornecimento de *feedback* imediato e o ajuste da dificuldade das tarefas podem motivar e envolver os alunos, promovendo uma aprendizagem mais eficaz.

**Exemplo prático:** Num jogo de ciências, o sistema pode ajustar a dificuldade dos puzzles e desafios com base nas respostas anteriores dos alunos, oferecendo tarefas mais difíceis para os alunos avançados e apoio adicional para os que precisam de mais ajuda.

# Capítulo 6

## Conclusão

### 6.1 Síntese dos Resultados

Este estudo apresentou uma modificação do algoritmo de Gale-Shapley, adaptando-o para cenários educacionais que requerem uma única lista de participantes baseada em métricas objetivas de compatibilidade. Ao substituir as preferências subjetivas por pontuações de compatibilidade calculadas a partir dos atributos dos alunos, o algoritmo modificado demonstrou melhorar a estabilidade e a qualidade dos emparelhamentos em contextos de aprendizagem colaborativa e competitiva.

Os resultados das simulações e aplicações práticas indicaram que o algoritmo é eficaz na formação de pares mais compatíveis, promovendo interações equilibradas entre os alunos. Observou-se que a utilização de métricas como a distância euclidiana inversa, a similaridade de Jaccard e a similaridade de cosseno contribuiu para a formação de pares com maior compatibilidade, sendo a similaridade de cosseno especialmente eficaz em contextos com dados numéricos.

Na aplicação em jogos educacionais competitivos, o algoritmo modificado não apenas aumentou a compatibilidade entre os pares, mas também melhorou o desempenho acadêmico médio dos alunos, reduziu a variabilidade nas pontuações e promoveu um ambiente de competição mais equilibrado e envolvente. A análise qualitativa do *feedback* dos alunos reforçou esses achados, indicando níveis mais altos de engajamento e satisfação com os pares formados.

A principal contribuição deste estudo reside na adaptação prática do algoritmo de Gale-Shapley para ambientes educacionais reais, onde uma única lista de participantes é a norma. Ao demonstrar a eficácia do algoritmo modificado na promoção de emparelhamentos estáveis e compatíveis, este trabalho oferece uma ferramenta valiosa para educadores e

desenvolvedores de tecnologias educacionais que buscam otimizar a aprendizagem colaborativa e competitiva.

## 6.2 Limitações

Apesar dos resultados promissores obtidos neste estudo, é importante reconhecer as limitações inerentes às metodologias utilizadas e considerar como elas influenciam os achados e as implicações para trabalhos futuros.

Uma limitação refere-se à dualidade dos testes realizados: um com dados simulados e outro com dados reais provenientes de jogos educacionais. No teste com dados simulados, embora tenhamos conseguido controlar rigorosamente as variáveis e avaliar o desempenho do algoritmo em diferentes cenários, os dados sintéticos podem não capturar a complexidade e a diversidade das interações humanas em contextos educacionais reais. Fatores como motivação intrínseca, dinâmica de grupo, preferências pessoais e influências socioemocionais não são facilmente replicáveis em dados gerados artificialmente. Assim, os resultados das simulações podem superestimar ou subestimar a eficácia do algoritmo quando aplicado em situações reais.

No teste com dados reais utilizando jogos educacionais, embora tenhamos obtido *insights* valiosos sobre a aplicação prática do algoritmo, o tamanho da amostra foi relativamente pequeno e restrito a um único contexto educacional e cultural. Além disso, os jogos utilizados podem ter limitações próprias, como design de interface, mecânicas de jogo e conteúdo educacional, que podem influenciar o engajamento dos alunos e, conseqüentemente, os resultados observados. Também é possível que fatores externos, como o ambiente escolar, a familiaridade com tecnologia e o suporte do professor, tenham impactado a eficácia da implementação.

Outra limitação está relacionada à generalização dos resultados. Embora o algoritmo tenha demonstrado eficácia na formação de pares compatíveis tanto nas simulações quanto na aplicação real, não podemos assumir que os mesmos resultados serão replicados em outros contextos educacionais, disciplinas ou faixas etárias sem a devida investigação. Diferentes

ambientes de aprendizagem apresentam desafios e dinâmicas únicas que podem afetar o desempenho do algoritmo.

## 6.3 Trabalhos Futuros

Para pesquisas futuras, é recomendável realizar estudos com amostras maiores e mais diversificadas, abrangendo diferentes níveis de ensino, disciplinas e contextos culturais. A validação do algoritmo em ambientes educacionais variados permitirá avaliar sua robustez e capacidade de generalização em cenários distintos. Além disso, implementar estudos longitudinais que acompanhem o desempenho dos alunos ao longo do tempo ajudará a compreender os efeitos de longo prazo da utilização do algoritmo na formação de pares e seu impacto contínuo no engajamento e na aprendizagem.

Explorar a integração do algoritmo com diferentes tecnologias educacionais também é uma direção promissora. A aplicação do algoritmo em conjunto com outras ferramentas e plataformas, como ambientes virtuais de aprendizagem, sistemas adaptativos e aplicativos móveis, pode potencializar os benefícios e oferecer soluções mais completas para educadores e alunos. O refinamento do algoritmo, considerando fatores adicionais como preferências pessoais, estilos de aprendizagem e aspectos socioemocionais, poderá aumentar sua eficácia. A incorporação de técnicas de inteligência artificial e aprendizado de máquina pode permitir adaptações mais dinâmicas e personalizadas, atendendo às necessidades específicas de cada aluno.

Além disso, aprofundar a análise qualitativa, coletando *feedback* detalhado de alunos e professores sobre a experiência com o algoritmo, será fundamental. Compreender as percepções, os desafios enfrentados e as sugestões dos usuários pode orientar melhorias e assegurar que a ferramenta atenda às necessidades reais do ambiente educacional. Considerar variáveis contextuais, como suporte institucional, formação docente e infraestrutura tecnológica, é essencial para avaliar plenamente a eficácia e viabilidade da implementação em larga escala.

Por fim, avaliar e otimizar o desempenho computacional do algoritmo, especialmente com o aumento do número de participantes. Técnicas como paralelização, algoritmos

aproximados e otimizações específicas podem tornar a aplicação mais eficiente e responsiva em ambientes com grande volume de dados. Abordar essas questões permitirá que o algoritmo seja aplicado de maneira eficaz em contextos educacionais diversos e em escala ampliada.

Ao considerar essas direções para trabalhos futuros, será possível consolidar a aplicabilidade do algoritmo de Gale-Shapley modificado em contextos educacionais variados, contribuindo para a inovação pedagógica e para a melhoria dos processos de aprendizagem colaborativa e competitiva.

## **6.4 Considerações Finais**

A utilização do algoritmo de Gale-Shapley modificado em contextos educacionais representa um avanço na personalização e otimização da aprendizagem colaborativa e competitiva. Ao promover a formação de pares mais estáveis e compatíveis, o algoritmo contribui para ambientes educacionais mais equitativos, eficazes e engajadores. Este estudo evidencia o potencial da integração entre tecnologia e pedagogia, mostrando que algoritmos bem projetados podem ter um impacto positivo na experiência de aprendizagem dos alunos.

É fundamental reconhecer que a tecnologia, quando aplicada de forma reflexiva e fundamentada, pode ser uma aliada poderosa na educação. A inovação trazida por este trabalho abre caminho para novas abordagens na formação de pares e grupos, incentivando a exploração contínua de soluções que atendam às demandas da era digital. Ao equilibrar considerações técnicas com as necessidades humanas e educacionais, podemos desenvolver ferramentas que não apenas aprimoram o desempenho acadêmico, mas também enriquecem o processo de aprendizagem como um todo.

Em suma, este estudo contribui para a literatura ao apresentar uma metodologia inovadora e prática para a formação de pares em contextos educacionais, adaptando um algoritmo clássico para atender às realidades modernas da sala de aula. Espera-se que pesquisas futuras continuem a expandir este trabalho, explorando novas aplicações, refinando o algoritmo e aprofundando a compreensão de como a tecnologia pode ser utilizada para promover uma educação mais personalizada, inclusiva e eficaz.

# Publicações

## ***Optimizing Social and Emotional Learning through Modified Gale-Shapley Algorithm for Collaborative and Competitive Education***

*Abstract—Collaborative and competitive learning is essential in educational development, enhancing students' social and emotional competencies critical for academic and personal success. This study explores the integration of the Gale-Shapley algorithm, initially designed for the stable marriage problem, to optimize student pairings in collaborative and competitive learning environments. The objective is to maximize the effectiveness of Social and Emotional Learning (SEL) interventions by fostering productive social interactions and essential skill development. We propose a modified version of the Gale-Shapley algorithm to handle a single list of students, utilizing compatibility scores based on inverse Euclidean distance, Jaccard similarity, and cosine similarity. Our methodology includes generating synthetic datasets to simulate various educational contexts and evaluate the algorithm's performance. Results demonstrate the algorithm's efficiency in forming stable and effective pairs, significantly enhancing the learning experience. This innovative approach aligns with SEL guidelines and contemporary educational requirements, offering a robust, personalized, and dynamic learning framework. Future research should focus on empirical validations in diverse educational settings to confirm the algorithm's effectiveness and scalability.*

2024 - **International Journal of Information and Education Technology (IJET)**

Qualis A4

CiteScore 2023 - **2.8**<sup>12</sup>

doi: [10.18178/ijiet.2024.14.11.2179](https://doi.org/10.18178/ijiet.2024.14.11.2179)<sup>13</sup>

---

<sup>12</sup> <https://www.scopus.com/sourceid/21100921050>

<sup>13</sup> <http://dx.doi.org/10.18178/ijiet.2024.14.11.2179>

## ***Implementation of Stable Pairing Algorithms for Optimizing Educational Games: A Computational and Pedagogical Perspective***

*Abstract—The Gale-Shapley algorithm solves the problem of stable pair formation across various fields including economics, labor markets, biology, computer science, and physics. This study modifies the algorithm to use a single list of participants and calculates compatibility scores using Jaccard similarity coefficients from students' proficiency tests and academic performance. We compared the effectiveness of this modified algorithm by evaluating two groups of students engaged in digital educational games: an experimental group matched by the modified algorithm and a randomly matched control group. The results show that the modified algorithm forms pairs with superior compatibility, consistent performance, and balanced competition. These findings suggest integrating the Gale-Shapley algorithm into educational technologies can enhance learning environments. The results significantly impact educational practices indicating that systematic peer training can improve collaboration, competition, and student engagement.*

**2024 - IEEE Latin America Transactions**

**Qualis A4**

**CiteScore 2023 - 3.5<sup>14</sup>**

**doi: 10.1109/TLA.2024.10790546<sup>15</sup>**

---

<sup>14</sup> <https://www.scopus.com/sourceid/19700181218>

<sup>15</sup> <http://dx.doi.org/10.1109/TLA.2024.10790546>

## Referências

ABDULKADIROĞLU, A.; PATHAK, P. A.; ROTH, A. E. Strategy-Proofness versus Efficiency in Matching with Indifferences: Redesigning the NYC High School Match. *American Economic Review*, v. 99, n. 5, p. 1954-1978, 2009. DOI: 10.1257/aer.99.5.1954.

ABDULKADIROĞLU, A.; SÖNMEZ, T. School choice: a mechanism design approach. *American Economic Review*, v. 93, n. 3, p. 729-747, 2003. DOI: 10.1257/000282803322157061.

CHANG, C.; LIN, C. Dormitory assignment using a genetic algorithm. *Applied Artificial Intelligence*, vol. 35, no. 15, p. 2276–2297, 15 Dec. 2021. DOI: 10.1080/08839514.2021.1999595. Available at: <https://doi.org/10.1080/08839514.2021.1999595>.

CHEN, S. et al. Stable Matching-Based Two-Way Selection in Multi-Label Active Learning with Imbalanced Data. *Information Sciences*, v. 610, p. 281–299, 2022. DOI: 10.1016/j.ins.2022.07.182.

CIPRIANO, C. et al. The state of evidence for social and emotional learning: A contemporary meta-analysis of universal school-based SEL interventions. *Child Development*, v. 94, n. 5, p. 1181–1204, Jul. 2023. DOI: 10.1111/cdev.13968.

CONNOLLY, T.; BOYLE, E.; MACARTHUR, E.; HAINEY, T.; BOYLE, J. M. A systematic literature review of empirical evidence on computer games and serious games. *Computers & Education*, v. 59, n. 2, p. 661-686, 2012.

DECI, Edward L.; RYAN, Richard M. Intrinsic Motivation and Self-Determination in Human Behavior. *Perspectives in Social Psychology*. New York: Springer, 1985. DOI: 10.1007/978-1-4899-2271-7.

DUBINS, L. E.; FREEDMAN, D. A. Machiavelli and the Gale-Shapley Algorithm. *American Mathematical Monthly*, v. 88, n. 7, p. 485-494, 1981.

DURLAK, J. A. et al. The Impact of Enhancing Students' Social and Emotional Learning: A Meta-Analysis of School-Based Universal Interventions. *Child Development*, v. 82, n. 1, p. 405–432, Jan. 2011. DOI: 10.1111/j.1467-8624.2010.01564.x.

EYUPOGLU, S. et al. Stable Marriage Problems with Ties and Incomplete Preferences: An Empirical Comparison of ASP, SAT, ILP, CP, and Local Search Methods. arXiv (Cornell University), 2021. DOI: 10.48550/arxiv.2108.05165.

FENOALTEA, E. M.; BAYBUSINOV, I. B.; ZHAO, J.; ZHOU, L.; ZHANG, Y. The stable marriage problem: an interdisciplinary review from the physicist's perspective. *Physics Reports*, v. 917, p. 1–79, 2021. DOI: 10.1016/j.physrep.2021.03.001.

FIDAN, M.; ERDEM, E. Knowledge-Based Stable Roommates Problem: A Real-World Application. *Theory and Practice of Logic Programming*, p. 1–18, 2021. DOI: 10.1017/s1471068421000302.

GAFNI, T.; COHEN, K. Distributed learning over Markovian fading channels for stable spectrum access. *IEEE Access*, v. 10, p. 46652–46669, 2022. DOI: 10.1109/access.2022.3171666.

GALE, D.; SHAPLEY, L. S. College Admissions and the Stability of Marriage. *American Mathematical Monthly*, v. 69, n. 1, p. 9-15, 1962. DOI: 10.2307/2312726.

GEE, James Paul. *What Video Games Have to Teach Us About Learning and Literacy*. New York: Palgrave Macmillan, 2003.

GEE, J. P. *Good video games + good learning: Collected essays on video games, learning, and literacy*. New York: Peter Lang, 2007.

GIRARD, E.; YUSRI, R.; ABUSITTA, A.; AÏMEUR, E. An Automated Stable Personalized Partner Selection for Collaborative Privacy Education. *International Journal of Integrating Technology in Education*, v. 10, n. 2, p. 9–22, 2021. DOI: 10.5121/ijite.2021.10202.

GOKHALE, A. A. Collaborative learning enhances critical thinking. *Journal of Technology Education*, v. 7, n. 1, Sep. 1995. DOI: 10.21061/jte.v7i1.a.2.

GUSFIELD, D.; IRVING, R. W. *The Stable Marriage Problem: Structure and Algorithms*. Cambridge: MIT Press, 1989.

HAMARI, J.; KOIVISTO, J.; SARSA, H. Does Gamification Work? -- A Literature Review of Empirical Studies on Gamification. 47th Hawaii International Conference on System Sciences (HICSS), 2014.

HUANG, Y.-M. Exploring students' acceptance of educational computer games from the perspective of learning strategy. *Australasian Journal of Educational Technology*, v. 35, n. 3, Jun. 2019. DOI: 10.14742/ajet.3330.

HUANG, W.; LI, P.; LI, B.; NIE, L.; BAO, H. Towards stable task assignment with preference lists and ties in spatial crowdsourcing. *Information Sciences*, vol. 620, p. 16–30, 1 Jan. 2023. DOI 10.1016/j.ins.2022.11.048.

IRVING, R. W. Stable Marriage and Indifference. *Discrete Applied Mathematics*, v. 48, n. 3, p. 261-272, 1994. DOI: 10.1016/0166-218X(94)90088-4.

JENKINS, H. *Convergence culture: Where Old and New Media Collide*. New York: NYU Press, 2006.

JOHNSON, David W.; JOHNSON, Roger T. *Learning Together and Alone: Cooperative, Competitive, and Individualistic Learning*. 5th ed. Boston: Allyn and Bacon, 1999.

JOHNSON, D. W.; JOHNSON, R. T. Cooperative Learning: Improving university instruction by basing practice on validated theory. *Journal on Excellence in College Teaching*, v. 25, p. 85–118, Jan. 2014.

KIM, Hyun-Chan; LEE, Sun-Young. The Impact of Group Dynamics on Team Learning. *Computers & Education*, v. 123, p. 37-50, 2018. DOI: 10.1016/j.compedu.2018.04.009.

KNUTH, D. E. *Mariages Stables*. Les Presses de l'Université de Montréal, 1976.

LAINE, T. H.; LINDBERG, R. S. N. Designing Engaging Games for Education: A Systematic Literature review on game motivators and design principles. *IEEE Transactions on Learning Technologies*, v. 13, n. 4, p. 804-821, 2020.

LEE, Jung-Keun; KANG, Hyo-Jin. Applying the Gale-Shapley Algorithm in Collaborative Learning Systems. *Journal of Educational Technology*, v. 32, n. 4, p. 320-334, 2016. DOI: 10.1016/j.jedt.2016.07.005.

LEI, Z.; QIAN, X.; UKKUSURI, S. V. Efficient proactive vehicle relocation for on-demand mobility service with recurrent neural networks. *Transportation Research Part C-emerging Technologies*, vol. 117, p. 102678, 1 Aug. 2020. DOI 10.1016/j.trc.2020.102678. Available at: <https://doi.org/10.1016/j.trc.2020.102678>.

MANLOVE, D. F. *Algorithmics of Matching Under Preferences*. New Jersey: World Scientific Publishing, 2013. DOI: 10.1142/8703.

MCGONIGAL, J. *Reality is broken: Why Games Make Us Better and How They Can Change the World*. New York: Penguin, 2011.

MLIKA, Z.; CHERKAOUI, S. Deep deterministic policy gradient to minimize the age of information in cellular V2X communications. *IEEE Transactions on Intelligent Transportation Systems*, v. 23, n. 12, p. 23597–23612, 2022. DOI: 10.1109/tits.2022.3190799.

PIAGET, J. *The Origins of intelligence in Children*. New York: International Universities Press, 1969.

PRINCE, Michael. Does Active Learning Work? A Review of the Research. *Journal of Engineering Education*, v. 93, n. 3, p. 223-231, 2004. DOI: 10.1002/j.2168-9830.2004.tb00809.x.

PRENSKY, M. *Digital game-based learning*. New York: McGraw-Hill, 2001.

RESTA, P.; LAFERRIÈRE, T. Technology in support of collaborative learning. *Educational Psychology Review*, v. 19, n. 1, p. 65-83, 2007.

ROTH, A. E. The Evolution of the Labor Market for Medical Interns and Residents: A Case Study in Game Theory. *Journal of Political Economy*, v. 92, n. 6, p. 991-1016, 1984. DOI: 10.1086/261296.

ROTH, A. E.; PERANSON, E. The Redesign of the Matching Market for American Physicians: Some Engineering Aspects of Economic Design. *American Economic Review*, v. 89, n. 4, p. 748-780, 1999. DOI: 10.1257/aer.89.4.748.

ROTH, A. E.; SÖNMEZ, T.; ÜNVER, M. U. Kidney exchange. *The Quarterly Journal of Economics*, v. 119, n. 2, p. 457-488, 2004. DOI: 10.1162/0033553041382157.

ROTH, A. E.; SOTOMAYOR, M. A. *Two-Sided Matching: A Study in Game-Theoretic Modeling and Analysis*. Cambridge: Cambridge University Press, 1990. DOI: 10.1017/CBO9780511528313.

RYAN, R. M.; RIGBY, C. S.; PRZYBYLSKI, A. K. The Motivational Pull of Video Games: A Self-Determination Theory Approach. *Motivation and Emotion*, v. 30, n. 4, p. 344-360, 2006.

SAIF, A. F. M. S.; MAHAYUDDIN, Z. R.; SHAPI'I, A. Augmented Reality based Adaptive and Collaborative Learning Methods for Improved Primary Education Towards Fourth Industrial Revolution (IR 4.0). *International Journal of Advanced Computer Science and Applications*, v. 12, n. 6, Jan. 2021. DOI: 10.14569/ijacsa.2021.0120672.

SHAFIGH, M.; AHMAD, S.; KIM, H. A secure and efficient stable matching scheme for cognitive radio networks using blockchain. *IEEE Transactions on Wireless Communications*, v. 20, n. 7, p. 4347-4362, 2023. DOI: 10.1109/twc.2023.3065734.

SLAVIN, R. E. Research on Cooperative Learning and Achievement: What we know, what we need to know. *Contemporary Educational Psychology*, v. 21, n. 1, p. 43-69, 1996.

TEKINBAS, K. S.; ZIMMERMAN, E. *Rules of play: Game Design Fundamentals*. Cambridge: MIT Press, 2003.

THIRUVADY, D.; MORGAN, K.; BEDINGFIELD, S.; NAZARI, A. Allocating students to industry placements using integer programming and ant colony optimisation. *Algorithms*, v. 14, n. 8, p. 219, 2021. DOI: 10.3390/a14080219.

VIET, H. H. et al. A Shortlist-Based Bidirectional Local Search for the Stable Marriage Problem. *Journal of Experimental and Theoretical Artificial Intelligence*, v. 32, n. 1, p. 147-163, 2019. DOI: 10.1080/0952813x.2019.1635655.

VLACHOPOULOS, D.; MAKRI, A. The effect of games and simulations on higher education: a systematic literature review. *International Journal of Educational Technology in Higher Education*, v. 14, n. 1, 2017.

VYGOTSKY, L. S. *Mind in Society: The development of higher psychological processes*. Cambridge: Harvard University Press, 1978.

YUSRI, Rita; ABUSITTA, Adel; AÏMEUR, Esma. Teens-Online: a Game Theory-Based Collaborative Platform for Privacy Education. *International Journal of Artificial Intelligence in Education*, vol. 31, no. 4, p. 726–768, 17 Nov. 2020. DOI 10.1007/s40593-020-00224-0. Available at: <https://doi.org/10.1007/s40593-020-00224-0>.

ZHAO, M.; WANG, Y.; ZHANG, X.; XU, C. Online doctor-patient dynamic stable matching model based on regret theory under incomplete information. *Socio-economic Planning Sciences*, v. 87, p. 101615, 2023. DOI: 10.1016/j.seps.2023.101615.

ZINS, J. E.; ELIAS, M. J. Social and Emotional Learning: promoting the development of all students. *Journal of Educational and Psychological Consultation*, v. 17, n. 2–3, p. 233–255, Jul. 2007. DOI: 10.1080/10474410701413152.

# APÊNDICE A – Formulário de Avaliação

Idade:

- 18 anos
- 19 anos
- Outro: \_\_\_\_\_

Gênero:

- Masculino
- Feminino
- Prefiro não mencionar

Como você classificaria seu nível de engajamento durante o jogo?

- Muito engajado
- Engajado
- Neutro
- Pouco engajado
- Nada engajado

O jogo "Labirinto da Educação" ajudou você a aprender de maneira mais eficaz?

- Sim
- Não

Quão desafiantes você achou os enigmas do jogo?

- Muito fáceis
- Fáceis
- Moderados
- Difíceis
- Muito difíceis

Você se sentiu motivado a resolver os desafios do jogo?

- Sim
- Não

Você acredita que o formato de salas do jogo contribuiu para o seu aprendizado?

- Sim
- Não

Em uma escala de 1 a 5, como você avalia a dinâmica e jogo educativo em termos de melhorar seu aprendizado?

- 1 (Muito ruim)
- 2 (Ruim)
- 3 (Neutro)
- 4 (Bom)
- 5 (Excelente)