

Técnicas de Autobalanceamento em Jogos Digitais - Mapeamento Sistemático da Literatura

Title: Dynamic Difficulty Adjustment Techniques - Systematic Mapping Study

Cristiano Barroso Serra, Tadeu Moreira de Classe, Sean Wolfgang Matsui Siqueira

¹Grupo de Pesquisa em Jogos Digitais para Contextos Complexos (JOCCOM)
Programa de Pós-Graduação em Informática (PPGI)
Universidade Federal do Estado do Rio de Janeiro (UNIRIO)
Rio de Janeiro – Brasil

cristianoserra@edu.unirio.br, tadeu.classe@uniriotec.br, sean@uniriotec.br

Abstract. Introduction: *Autobalancing is an important strategy for dynamically adjusting the difficulty in digital games, but it still lacks systematization regarding the techniques, data, and validation methods used. Objective:* This article presents a Systematic Literature Mapping (SLM) on autobalancing in games, focusing on applied techniques, data types, and validation strategies. *Methodology:* The study was based on the framework proposed by Kitchenham and Charters and conducted across six databases, resulting in 1532 studies. After screening, 25 studies were analyzed based on five research questions. **Results:** The findings highlight AI/ML-based techniques and structured frameworks. Most studies use performance data and quantitative validation methods. Difficulty adjustment is the most commonly addressed mechanic. Most games are entertainment-oriented with a balanced distribution between 2D and 3D environments. The study contributes to more robust and personalized autobalancing practices.

Keywords. *Digital Game, Dynamic Difficulty Adjustment, Systematic Mapping.*

Resumo. Introdução: *O autobalanceamento é uma estratégia importante para ajustar dinamicamente a dificuldade em jogos digitais, mas ainda carece de sistematização quanto às técnicas, dados e validações utilizadas. Objetivo:* Este artigo apresenta um Mapeamento Sistemático da Literatura (MSL) sobre autobalanceamento em jogos, focando em técnicas aplicadas, tipos de dados e estratégias de validação. **Metodologia:** A pesquisa foi baseada na estrutura proposta Kitchenham e Charters e realizada em seis bases de dados, resultando em 1532 estudos. Após triagem, 25 estudos foram analisados com base em cinco questões de pesquisa. **Resultados:** Destacam-se técnicas baseadas em IA/ML e frameworks estruturados. A maioria dos estudos usa dados de desempenho e validação quantitativa. O ajuste de dificuldade é a principal mecânica abordada. A maioria dos jogos é voltada ao entretenimento com cenários 2D e 3D equilibrados. O estudo contribui para práticas mais robustas e personalizadas de autobalanceamento.

Palavras-chave. *Jogos Digitais, Autobalanceamento, Mapeamento Sistemático.*

1. Introdução

Os jogos digitais evoluíram para além do entretenimento, tornando-se ferramentas relevantes em educação, treinamento e saúde [Leitão et al. 2021]. O autobalanceamento,

ou ajuste dinâmico de dificuldade, refere-se à capacidade dos jogos de adaptarem seu nível de desafio com base no desempenho do jogador [Pfau et al. 2020]. Essa adaptação aumenta o engajamento e otimiza o aprendizado, especialmente em jogos sérios e educacionais, nos quais o equilíbrio entre desafio e acessibilidade impacta diretamente a eficácia e a satisfação [Camillo e Medeiros 2018].

O autobalanceamento influencia aspectos como motivação, aprendizado adaptativo e bem-estar emocional [Pfau et al. 2020]. Em contextos educacionais, jogos adaptativos oferecem desafios compatíveis com as habilidades dos alunos, promovendo progresso sem frustração. Em sistemas computacionais, o conceito é aplicado para ajustar dinamicamente a experiência do usuário, melhorando a usabilidade e a eficácia [Moon e Seo 2020].

Este estudo busca responder à seguinte questão de pesquisa: **“Quais técnicas de autobalanceamento são utilizadas em jogos digitais?”** Para isso, foi conduzido um Mapeamento Sistemático da Literatura (MSL), com rigor metodológico. Inicialmente, 1532 estudos foram identificados, dos quais 16 foram selecionados por sua relevância. As técnicas foram categorizadas, sua eficácia avaliada, as mecânicas de jogo afetadas analisadas e os gêneros mais beneficiados identificados. A maioria dos estudos apresentou técnicas de IA/ML e métricas de desempenho (72%) para autobalanceamento. Destacam-se o ajuste de dificuldade como principal mecânica adaptada e a predominância de jogos de entretenimento.

Este artigo está organizado da seguinte forma: a Seção 2 apresenta os principais conceitos sobre autobalanceamento; a Seção 3 discute trabalhos correlatos; a Seção 4 descreve o planejamento e execução do MSL; a Seção 5 detalha os resultados obtidos; e a Seção 6 traz as considerações finais e perspectivas futuras.

2. Autobalanceamento em Jogos

O autobalanceamento em jogos digitais é uma técnica que ajusta a dificuldade de forma dinâmica, conforme o desempenho do jogador. Seu principal objetivo é oferecer uma experiência desafiadora e acessível, aumentando o engajamento, a satisfação e o tempo de permanência no jogo [Altimira et al. 2017, Xia e Anand 2016, Moon e Seo 2020]. No *design* de jogos, esse balanceamento atua sobre mecânicas estruturadas por regras lógicas e matemáticas, como controle de turnos, pontuação, recompensas e curvas de aprendizado. Um bom balanceamento garante o funcionamento adequado do jogo e uma experiência justa [Xia e Anand 2016, Pfau et al. 2020].

As abordagens podem ser divididas em balanceamento estático, definido no desenvolvimento e mantido após o lançamento, e balanceamento dinâmico, que ajusta tarefas, recursos e adversários em tempo real com base nas ações do jogador.

Na prática, o autobalanceamento permite modificar a complexidade das tarefas, regular dinamicamente itens como vidas ou armas e adaptar o comportamento dos inimigos [Altimira et al. 2017]. Se o desempenho do jogador for baixo, o sistema reduz o desafio; se for alto, o desafio é elevado gradualmente. Isso é especialmente útil em jogos educativos e de treinamento, pois contribui diretamente para a aprendizagem [Camillo e Medeiros 2018, Leitão et al. 2021]. Além disso, o autobalanceamento favorece experiências inclusivas, adaptando o jogo a diferentes perfis e níveis de habilidade, e é

fundamental para manter o equilíbrio competitivo entre jogadores iniciantes e experientes [Moon e Seo 2020].

3. Trabalhos Relacionados

Hee-Seung Moon e Jiwon Seo [Moon e Seo 2020] propuseram, em 2020, um método de Ajuste Dinâmico de Dificuldade (DDA) baseado em *Meta-Adaptive Machine Learning (MAML)*, capaz de adaptar a dificuldade com poucos dados, superando abordagens tradicionais em testes com *Air Hockey virtual*. Em 2023, Cardouzo e Classe [Cardouzo e de Classe 2023] realizaram uma Revisão Rápida da Literatura (RRL) e destacaram a predominância do DDA em jogos de ação, mas identificaram uma lacuna na integração de elementos estéticos. Este estudo contribui ampliando esse panorama, ao sistematizar técnicas, dados utilizados, métodos de validação e tipos de jogos beneficiados pelo autobalanceamento.

4. Planejamento do Mapeamento Sistemático de Literatura

Este estudo segue as etapas do modelo de Mapeamento Sistemático da Literatura (MSL), conforme proposto por Kitchenham e Charters [Kitchenham 2004]. O processo é dividido em três fases: planejamento, condução e divulgação dos resultados. Essa abordagem permite uma revisão aprofundada da literatura em uma área de investigação, possibilitando a identificação, avaliação e interpretação de estudos relevantes.




Figura 1. Etapas do MSL

4.1. Planejamento

O planejamento do estudo foi orientado pela elaboração de um protocolo que guiou todas as fases da pesquisa. Esse protocolo incluiu: i) objetivo do estudo; ii) formulação das questões de pesquisa; iii) escolha das bases de dados; iv) construção da *string* de busca; v) critérios de inclusão, exclusão e avaliação da qualidade dos estudos; vi) uso da técnica de *snowballing* (backward e forward), com o objetivo de ampliar a seleção por meio de referências e citações dos artigos identificados.

O objetivo foi definido com base na seguinte pergunta: **Como jogos digitais utilizam técnicas de autobalanceamento?** A estruturação do protocolo seguiu a abordagem GQM (*Goal-Question-Metrics*) [Basili 1992], sendo descrita da seguinte forma: **analisar** a existência de estudos primários; **com o propósito de** identificar técnicas e conceitos de autobalanceamento; **relacionados a** como são usados, aplicados e implantados; **do ponto de vista de** pesquisadores; **no contexto de** jogos digitais.

A partir desse objetivo, foram definidas cinco questões secundárias de pesquisa:

Q1: Que técnicas de autobalanceamento são utilizadas em jogos digitais?

- Q2:** Que tipo de dados são coletados para o autobalanceamento do jogo criado?
- Q3:** Quais ferramentas foram utilizadas para validar a eficácia da utilização do autobalanceamento?
- Q4:** Quais as mecânicas do jogo criado que são influenciadas pelo balanceamento?
- Q5:** Qual tipo de jogo foi criado?

Para a seleção das fontes, foram utilizadas as principais bases de dados que indexam publicações da área de computação e jogos digitais [Keele et al. 2007]: *ACM Digital Library*¹, *EI Compendex*², *IEEE Xplore*³, *Scopus*⁴, *ISI Web of Science*⁵ e *SpringerLink*⁶.

A estratégia de busca foi definida com base na estrutura PICOC (*Population, Intervention, Comparison, Outcome, Context*) [Santos et al. 2007], utilizando apenas os elementos População e Intervenção. O uso completo do PICOC resultou em uma delimitação excessiva, reduzindo os resultados nas buscas. Como mostra a Tabela 1, a estrutura foi utilizada para organizar a *string* de busca.

Tabela 1. Termos e sinônimos usados no PICOC

Dimensão	Termo em Português	Termo em inglês
População	Jogos Digitais	<i>Digital Game</i>
Intervenção	Autobalanceamento	<i>Dynamic Difficulty Adjustment</i> "OR" "DDA"

Durante a formulação da *string*, foram incluídos sinônimos e traduções em inglês dos termos-chave. A string final foi definida como:

("Digital game")
AND
("DDA" OR "Dynamic Difficulty Adjustment")

Em seguida, foram definidos os critérios de inclusão e exclusão, conforme apresentado na Tabela 2. Os estudos que atendessem a todos os critérios de inclusão foram selecionados para leitura completa, enquanto aqueles que se enquadrassem em ao menos um critério de exclusão foram descartados.

Tabela 2. Critérios de Inclusão e Exclusão

Código	Descrição.
CI-1	Estudo que aborde o uso de autobalanceamento em jogos digitais.
CE-1	Estudo com acesso indisponível para visualização completa nas bases de dados científicas.
CE-2	Estudo com menos de 4 páginas.
CE-3	Estudo duplicado.
CE-4	Estudo que não aborde o uso de autobalanceamento em jogos digitais.
CE-5	Estudo que não seja primário.
CE-6	Estudo que não esteja escrito nos idiomas português ou inglês.
CE-7	Estudo que seja prefácio, livro, editorial, resumo, pôster, painel, palestra, mesa redonda, oficina, keynotes, tutoriais ou demonstração.

Na etapa de aceitação, foram utilizados seis critérios de qualidade (Tabela 3), cada um avaliado com uma pontuação de 0 ou 1, de acordo com seu atendimento. A soma dessas pontuações permitiu avaliar a robustez metodológica dos estudos selecionados.

¹<https://dl.acm.org/>

²<http://www.engineeringvillage.com>

³<http://ieeexplore.ieee.org>

⁴<http://www.scopus.com>

⁵<http://www.isiknowledge.com>

⁶<http://link.springer.com>

Tabela 3. Critérios de Qualidade

Código	Descrição
CQ1	O estudo responde todas as questões de pesquisa?
CQ2	O objetivo do estudo está definido de forma clara?
CQ3	Existe secção de trabalhos relacionados, no qual diferencia a proposta do estudo de outros trabalhos?
CQ4	A metodologia da pesquisa é claramente definida e apresentada?
CQ5	Os resultados estão claramente apresentados?
CQ6	O estudo apresenta claramente o contexto de autobalanceamento para qual o jogo foi aplicado?

Para apoio ao planejamento e à organização das referências, foi utilizado o sistema *Parsif.al*⁷. O processo de análise foi dividido em três etapas: remoção de duplicatas (etapa 1), seleção inicial dos estudos (etapa 2) e aceitação final com base nos critérios definidos (etapa 3). Embora o *Parsif.al* tenha sido útil nas etapas iniciais, a organização e análise detalhada dos dados foram realizadas no *Microsoft Excel*.

4.2. Condução do MSL

Foram identificados 1532 estudos entre janeiro e dezembro de 2024. Após a remoção de duplicatas (572 estudos, 37%), restaram 960. Na etapa de seleção, 935 foram excluídos por não atenderem aos critérios de inclusão, resultando em 25 estudos selecionados (1,6%), conforme mostrado na Tabela 4.

Tabela 4. Relação de estudos em cada etapa do MSL

Base	Busca	Etapa 1		Etapa 2	
		Duplicados		Seleção	
		Removidos	Restantes	Removidos	Aceitos
ACM Digital Library	344	41	303	301	2
El Compendex	250	196	54	48	6
IEEE Digital Library	79	56	23	20	3
Scopus	285	208	77	74	3
Web of Science	177	18	159	151	8
Springer	397	53	344	341	3
Total	1532	572	960	935	25

5. Resultados

5.1. Análise Preliminar dos Estudos Aceitos

A Tabela 5 apresenta os 25 estudos aceitos para análise, identificados por um código (ID). Para cada estudo, são informados o ano de publicação, o título e a pontuação de qualidade após a leitura completa. Como mostra a Figura 2, os estudos sobre autobalanceamento em jogos digitais tem sido produzidos desde 2005. A partir de 2008, observa-se um aumento expressivo, indicando um crescente interesse na temática. Todos os 25 estudos atingiram a pontuação máxima de qualidade (6 pontos), o que sugere resultados metodologicamente robustos e potencialmente confiáveis.

⁷<https://parsif.al/>

Tabela 5: Estudos aceitos

ID	Ano	Título	Quali.
E-01	2015	A Data-driven Approach for Online Adaptation of Game Difficulty [Yin et al. 2015]	6
E-02	2019	A Pilot Study on the Feasibility of Dynamic Difficulty Adjustment in Game-Based Learning [Ninaus et al. 2019]	6
E-03	2015	Adaptation in Digital Games: The Effect of Challenge Adjustment [Denisova e Cairns 2015]	6
E-04	2006	Adaptive Game AI with Dynamic Scripting [Spronck et al. 2006]	6
E-05	2022	AI-enabled Prediction of Video Game Player Performance [Smerdov et al. 2023]	6
E-06	2018	Development and Assessment of an Adaptive Difficulty Arithmetic Game-Based Learning Object [Mainieri et al. 2018]	6
E-07	2017	Dynamic Difficulty Adjustment for Maximized Engagement [Xue et al. 2017]	6
E-08	2020	Dynamic Difficulty Adjustment in Digital Games Using Genetic Algorithms [Weber e Notargiacomo 2020]	6
E-09	2016	Dynamic Difficulty Adjustment on MOBA Games [Silva et al. 2016]	6
E-10	2017	Dynamic Pressure Cycle Control: Dynamic Difficulty Adjustment [Masanobu et al. 2017]	6
E-11	2018	Emotion-based Dynamic Difficulty Adjustment Using Parameterized Difficulty [Frommel et al. 2018]	6
E-12	2023	Fuzzy-based Dynamic Difficulty Adjustment of an Educational 3D-game [Chrysafiadi et al. 2023]	6
E-13	2021	Towards a Concept for a Hidden Object Game with Dynamic Difficulty Adjustment [Atorf et al. 2021]	6
E-14	2025	Extending a MAPE-K loop-based framework for Dynamic Difficulty Adjustment [Souza et al. 2025]	6
E-15	2010	Micro-adaptivity: Protecting Immersion in Didactically Adaptive Digital Educational Games [Kickmeier-Rust e Albert 2010]	6
E-16	2017	Visual Data Exploration for Balance Quantification During Exergaming [Soancatl et al. 2016]	6
E-17	2019	δ -logit: Dynamic Difficulty Adjustment Using Few Data Points [Rao Fernandes e Levieux 2019]	6
E-18	2019	A Health Point-Based Dynamic Difficulty Adjustment Strategy for Video Games [Suaza et al. 2019]	6
E-19	2022	AlphaDDA: Strategies for Adjusting the Playing Strength of a Fully Trained AlphaZero System [Fujita 2022]	6
E-20	2023	Behavioral and Psychophysiological Measures of Engagement During Dynamic Difficulty Adjustment in Immersive Virtual Reality [Caldas et al. 2023]	6
E-21	2024	Dynamic Difficulty Adaptation Based on Stress Detection for a Virtual Reality Video Game: A Pilot Study [Orozco-Mora et al. 2024]	6
E-22	2022	Improved Belgian AI Algorithm for Dynamic Management in Action Role-Playing Games [Mi e Gao 2022]	6
E-23	2022	Keep Calm and Aim for the Head: Biofeedback-Controlled Dynamic Difficulty Adjustment in a Horror Game [Moschovitis e Denisova 2022]	6
E-24	2017	Learning Constructive Primitives for Real-time Dynamic Difficulty Adjustment in Super Mario Bros [Shi e Chen 2017]	6
E-25	2020	User Evaluation of Affective Dynamic Difficulty Adjustment Based on Physiological Deep Learning [Chanel e Lopes 2020]	6

5.2. Q1: Que técnicas de autobalanceamento são utilizadas em jogos digitais?

Esta questão investigou as técnicas de autobalanceamento empregadas nos jogos digitais, com base na análise de 25 estudos. A maioria adota abordagens de inteligência artificial e aprendizado de máquina (IA/ML), presentes em 40% dos casos (10 estudos: E-01, E-04, E-05, E-08, E-12, E-17, E-19, E-22, E-24, E-25), incluindo redes neurais, algoritmos genéticos, regressão logística e modelos de *deep learning*. Além disso, 16% dos estudos (E-13, E-14, E-15, E-16) utilizaram *frameworks* estruturados, como MAPE-K, micro-adaptabilidade e modelos baseados em metas, que combinam múltiplas estratégias de autobalanceamento de forma integrada.




Figura 2. Distribuição de estudos por ano de publicação.

A seguir, são apresentados dois exemplos (Listing 1 e Listing 2) de modelos matemáticos utilizados para ajuste dinâmico de dificuldade em jogos digitais, descritos por meio de expressões matemáticas e princípios computacionais. Esses modelos foram representados como listagens para facilitar sua referência técnica:

Listing 1. DDA-MAPEKit: Coeficiente de Ajuste baseado no Desempenho

```

1 # O modelo DDA-MAPEKit utiliza um coeficiente de ajuste para
  # alinhar a dificuldade ao desempenho do jogador, definido pela
  # fórmula:
2
3 AC = (AVG - 1) * K
4 # AC = Coeficiente de Ajuste
5 # AVG = Média do desempenho do jogador
6 # K = Constante definida pelo designer do jogo

```

Listing 2. δ -logit: Dynamic Difficulty Adjustment Using Few Data Points

```

1 # Este modelo utiliza regressão logística para estimar a
  # probabilidade de falha do jogador e ajusta dinamicamente a
  # dificuldade com um delta:
2 P(fail |  $\theta$ ) = 1 / (1 + e-(a $\theta$  + b))
3
4 # A dificuldade é ajustada conforme:  $\theta = \theta \pm \delta$ 
5 #  $\theta$  = Parâmetro de dificuldade
6 # a, b = Parâmetros da regressão logística
7 #  $\delta$  = Incremento para ajuste dinâmico

```

5.3. Q2: Que tipo de dados são coletados para o autobalanceamento do jogo criado?

Os dados coletados para o autobalanceamento variam conforme o foco de cada estudo. A categoria mais frequente envolve dados de **desempenho**, presente em 72% dos casos (18 estudos), com métricas relacionadas a tempo, acertos, erros e progresso (E-01, E-02 ... E-24). Dados **fisiológicos e psicológicos** foram utilizados em 28% dos estudos,




Figura 3. Principais técnicas identificadas.

incluindo batimentos cardíacos, indicadores de estresse e autorrelatos emocionais. Já os dados **comportamentais**, observados em 20% dos estudos, referem-se a ações como movimentação e decisões tomadas durante o jogo. As **métricas do jogo**, presentes em 16% dos estudos, englobam informações como fase atual, quantidade de recursos e elementos da interface (HUD). Por fim, dados de **interações** do jogador com o sistema, como cliques, uso de menus e comandos, aparecem em 12% dos estudos.




Figura 4. Tipos de dados coletados.

5.4. Q3: Quais ferramentas foram utilizadas para validar a eficácia da utilização do autobalanceamento?

As principais formas de validação observadas nos estudos analisados foram diversas. As **análises quantitativas** estiveram presentes em 56% dos estudos (14 no total), utilizando testes estatísticos, correlações e métricas de desempenho. A participação de **usuários reais** foi observada em 44% dos casos, contribuindo com dados empíricos para a validação. Aproximadamente 24% dos estudos utilizaram **experimentos controlados**, por meio da construção de protótipos específicos. Já os **instrumentos qualitativos**, como entrevistas e questionários, foram empregados em 20% dos estudos. Por fim, 16% dos trabalhos adotaram **protocolos experimentais**, estruturando a validação com delineamentos rigorosos e critérios pré-definidos.

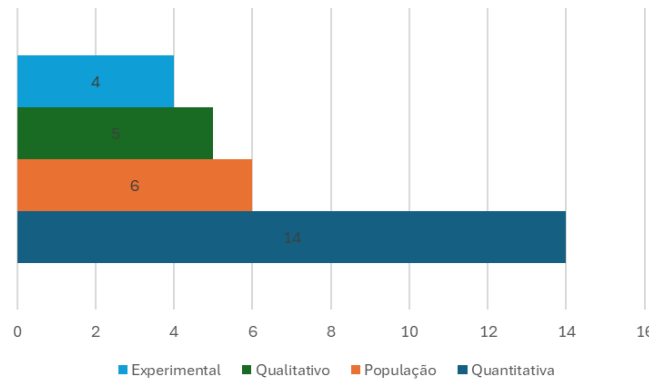


Figura 5. Formas de validação.

5.5. Q4: Quais as mecânicas do jogo criado que são influenciadas pelo balanceamento?

As principais mecânicas influenciadas pelo autobalanceamento, conforme os estudos analisados, incluem o **ajuste de dificuldade**, presente em 52% dos casos, que envolve a modulação do nível de desafio enfrentado pelo jogador. Em seguida, **ritmo e intensidade** aparecem em 28% dos estudos, com variações na frequência e na velocidade dos desafios apresentados. A mecânica de **combate**, relacionada a padrões de ataque e comportamento da inteligência artificial dos inimigos, é abordada em 24% dos estudos. A **pontuação e o feedback** adaptativo foram mencionados em 20% dos trabalhos, fornecendo respostas baseadas no desempenho do jogador. Por fim, **conteúdo e ambiente**, com foco na geração procedural de fases ou posicionamento dinâmico de elementos, foram explorados em 24% dos estudos.




Figura 6. Mecânicas influenciadas.

5.6. Q5: Qual tipo de jogo foi criado?

A classificação dos tipos de jogos analisados nos estudos contempla diferentes finalidades e características visuais. Os **jogos com propósito**, como os voltados à educação ou treinamento, correspondem a 24% dos casos, enquanto os **jogos de entretenimento** são maioria, presentes em 68% dos estudos. Os **exergames**, com foco em atividades físicas ou reabilitação, aparecem em 8% dos trabalhos. Quanto à ambientação gráfica, os

cenários 3D foram empregados em 48% dos estudos, mesma proporção observada para os **cenários 2D**. Além disso, 4% dos estudos adotaram ambientes **2.5D**⁸, que mesclam aparência tridimensional com movimentação em dois eixos.




Figura 7. Tipos de jogos analisados.

6. Considerações Finais e Trabalhos Futuros

Este mapeamento sistemático analisou 1532 estudos, dos quais 25 foram selecionados conforme critérios rigorosos. Os resultados revelam a ampla variedade de estratégias de autobalanceamento em jogos digitais, incluindo abordagens com IA/ML, frameworks adaptativos, diferentes tipos de dados e validações.

Sobre as técnicas (Q1), 40% dos trabalhos empregam IA/ML, 16% utilizam frameworks como o MAPE-K, e alguns combinam IA com biofeedback. Quanto aos dados utilizados (Q2), 72% baseiam-se em métricas de desempenho e 28% em dados fisiológicos ou psicológicos, indicando uma busca por personalização.

Na avaliação da eficácia (Q3), métodos quantitativos prevalecem (56%), seguidos por qualitativos (20%). As principais mecânicas ajustadas (Q4) foram dificuldade (52%), ritmo/intensidade (28%) e combate (24%).

A maioria dos jogos (Q5) é voltada ao entretenimento (68%), com menor foco em jogos sérios (24%) e exergames (8%). Os ambientes são quase igualmente distribuídos entre 2D e 3D (48% cada), com baixa incidência de 2.5D (4%).

Entre as perspectivas futuras, destacam-se a formalização matemática das abordagens, o estudo de custos computacionais e a integração de dados variados. Recomenda-se também validações mais robustas, combinando métodos qualitativos, quantitativos e experimentais. Este estudo oferece uma visão abrangente do estado da arte e propõe caminhos promissores para avanços na área.

Agradecimentos

Os autores agradecem a Fundação Carlos Chagas Filho de Amparo à Pesquisa do Estado do Rio de Janeiro – FAPERJ (proc. E-26/204.478/2024 - SEI-260003/013219/2024) por financiar parcialmente esta pesquisa.

⁸Jogos 2.5D combinam gráficos 3D com jogabilidade restrita a um plano 2D.

Referências

- Altimira, D., Mueller, F. F., Clarke, J., Lee, G., Billingham, M., e Bartneck, C. (2017). Enhancing player engagement through game balancing in digitally augmented physical games. *International Journal of Human-Computer Studies*, 103:35–47.
- Atorf, D., Dyck, S., e Steinbach, J. (2021). Towards a concept for a hidden object game with dynamic difficulty adjustment. *COGNITION AND EXPLORATORY LEARNING IN THE DIGITAL AGE (CELDA 2021)*, page 311.
- Basili, V. R. (1992). *Software modeling and measurement: the Goal/Question/Metric paradigm*. University of Maryland at College Park.
- Caldas, O. I., Maledoux, M., Aviles, O. F., e Rodriguez-Guerrero, C. (2023). Behavioral and psychophysiological measures of engagement during dynamic difficulty adjustment in immersive virtual reality. *Journal of Universal Computer Science*, 29(1):16–33.
- Camillo, C. M. e Medeiros, L. M. (2018). A importância dos jogos digitais no contexto escolar. *Revista Competência*.
- Cardouzo, H. H. e de Classe, T. M. (2023). Balanceamento em estéticas e dinâmicas para imersão em certos gêneros de jogos-revisão rápida da literatura. *Anais Estendidos do XXII Simpósio Brasileiro de Jogos e Entretenimento Digital*, pages 200–212.
- Chanel, G. e Lopes, P. (2020). User evaluation of affective dynamic difficulty adjustment based on physiological deep learning. In *International Conference on Human-Computer Interaction*, pages 3–23. Springer.
- Chrysafiadi, K., Kamitsios, M., e Virvou, M. (2023). Fuzzy-based dynamic difficulty adjustment of an educational 3d-game. *Multimedia Tools and Applications*, 82(18):27525–27549.
- Denisova, A. e Cairns, P. (2015). Adaptation in digital games: the effect of challenge adjustment on player performance and experience. In *Proceedings of the 2015 Annual Symposium on Computer-Human Interaction in Play*, pages 97–101.
- Frommel, J., Fischbach, F., Rogers, K., e Weber, M. (2018). Emotion-based dynamic difficulty adjustment using parameterized difficulty and self-reports of emotion. In *Proceedings of the 2018 annual symposium on computer-human interaction in play*, pages 163–171.
- Fujita, K. (2022). Alphadda: strategies for adjusting the playing strength of a fully trained alphazero system to a suitable human training partner. *PeerJ Computer Science*, 8:e1123.
- Keele, S. et al. (2007). Guidelines for performing systematic literature reviews in software engineering.
- Kickmeier-Rust, M. D. e Albert, D. (2010). Micro-adaptivity: Protecting immersion in didactically adaptive digital educational games. *Journal of Computer Assisted Learning*, 26(2):95–105.
- Kitchenham, B. (2004). Procedures for performing systematic reviews. *Keele, UK, Keele University*, 33(2004):1–26.

- Leitão, T., Navarro, L. L. L., Cameira, R. F., e Silva, É. R. (2021). Serious games in business process management: a systematic literature review. *Bus. Process. Manag. J.*, 27:685–721.
- Mainieri, B. O., Azevedo, V. L., Braga, P. H. C., e Omar, N. (2018). Development and assessment of an adaptive difficulty arithmetic game based learning object. In *2018 XIII Latin American Conference on Learning Technologies (LACLO)*, pages 232–239. IEEE.
- Masanobu, E., Mikami, K., et al. (2017). Dynamic pressure cycle control: Dynamic difficulty adjustment beyond the flow zone. In *2017 Nicograph International (NicoInt)*, pages 9–14. IEEE.
- Mi, Q. e Gao, T. (2022). Improved belgian ai algorithm for dynamic management in action role-playing games. *Applied Sciences*, 12(22):11860.
- Moon, H.-S. e Seo, J. (2020). Dynamic difficulty adjustment via fast user adaptation. In *Adjunct Proceedings of the 33rd Annual ACM Symposium on User Interface Software and Technology*, pages 13–15.
- Moschovitis, P. e Denisova, A. (2022). Keep calm and aim for the head: Biofeedback-controlled dynamic difficulty adjustment in a horror game. *IEEE Transactions on Games*, 15(3):368–377.
- Ninaus, M., Tsarava, K., e Moeller, K. (2019). A pilot study on the feasibility of dynamic difficulty adjustment in game-based learning using heart-rate. In *Games and Learning Alliance*, pages 117–128. Springer.
- Orozco-Mora, C. E., Fuentes-Aguilar, R. Q., e Hernández-Melgarejo, G. (2024). Dynamic difficulty adaptation based on stress detection for a virtual reality video game: A pilot study. *Electronics*, 13(12):2324.
- Pfau, J., Smeddinck, J. D., e Malaka, R. (2020). Enemy within: Long-term motivation effects of deep player behavior models for dynamic difficulty adjustment. *Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems*.
- Rao Fernandes, W. e Levieux, G. (2019). -logit: Dynamic difficulty adjustment using few data points. In *Joint International Conference on Entertainment Computing and Serious Games*, pages 158–171. Springer.
- Santos, C. M. d. C., Pimenta, C. A. d. M., e Nobre, M. R. C. (2007). A estratégia pico para a construção da pergunta de pesquisa e busca de evidências. *Revista latino-americana de enfermagem*, 15:508–511.
- Shi, P. e Chen, K. (2017). Learning constructive primitives for real-time dynamic difficulty adjustment in super mario bros. *IEEE Transactions on Games*, 10(2):155–169.
- Silva, M. P., Silva, V. d. N., e Chaimowicz, L. (2016). Dynamic difficulty adjustment on moba games. *Entertainment Computing*, 17:41–49.
- Smerdov, A., Somov, A., Burnaev, E., e Stepanov, A. (2023). Ai-enabled prediction of video game player performance using the data from heterogeneous sensors. *Multimedia Tools and Applications*, 82(7):11021–11046.

- Soanacatl, V., van de Gronde, J. J., Lamoth, C., Maurits, N. M., e Roerdink, J. B. (2016). Visual data exploration for balance quantification during exergaming. In *EuroVis (Posters)*, pages 25–27.
- Souza, C. H. R., de Oliveira, S. S., Berretta, L. O., e Carvalho, S. T. (2025). Extending a mape-k loop-based framework for dynamic difficulty adjustment in single-player games. *Entertainment Computing*, 52:100842.
- Spronck, P., Sprinkhuizen-Kuyper, I., e Postma, E. O. (2006). Adaptive game ai with dynamic scripting. *Machine Learning*, 63(3):217–248.
- Suaza, J., Gamboa, E., e Trujillo, M. (2019). A health point-based dynamic difficulty adjustment strategy for video games. In *Joint International Conference on Entertainment Computing and Serious Games*, pages 436–440. Springer.
- Weber, M. e Notargiacomo, P. (2020). Dynamic difficulty adjustment in digital games using genetic algorithms. In *2020 19th Brazilian Symposium on Computer Games and Digital Entertainment (SBGames)*, pages 62–70. IEEE.
- Xia, W. e Anand, B. (2016). Game balancing with ecosystem mechanism. In *2016 international conference on data mining and advanced computing (SAPIENCE)*, pages 317–324. IEEE.
- Xue, S., Wu, M., Kolen, J., Aghdaie, N., e Zaman, K. A. (2017). Dynamic difficulty adjustment for maximized engagement in digital games. In *Proceedings of the 26th international conference on world wide web companion*, pages 465–471.
- Yin, H., Luo, L., Cai, W., Ong, Y.-S., e Zhong, J. (2015). A data-driven approach for online adaptation of game difficulty. In *2015 IEEE conference on computational intelligence and games (CIG)*, pages 146–153. IEEE.