

# Model for Automatic Generation of Difficulty Curves in Digital Games

Saulo M. Corrêa, Paulo R. Santos, Bernardo B. Cerqueira, João B. Mossmann e Débora N. F. Barbosa

**Abstract**—This paper presents a model for the generation of difficulty curves adaptive to the user's context. From studies on Flow theory combined with difficulty curves, element of digital game development process, mathematical models and previous data were used to create an adaptive difficulty curve based on user performance. It was used a research developed digital game as a case study, ‘The Incredible Adventures of Apollo & Rosetta in the Space’, which provided previous user data to perform the statistical analysis. Through the applied study, it is proposed the Difficulty Curves Generator Model (DCGM) for the generation of adaptive difficulty curves in digital games. Different approaches were used, and the final results demonstrated via simulation of the DCGM the ability of the generator to predict and adjust the game level for the player to experience, by calculating the relation between difficulty and player performance, aimed and focused in the Flow state.

**Index Terms** — Digital Games. Difficulty Curves. User Experience. Apollo & Rosetta.

## I. INTRODUÇÃO

Engenharia de *Software* (ES) busca modelos de desenvolvimento adequados ao contexto dos produtos a serem construídos. No contexto da produção de *softwares* como os jogos digitais, estudos provenientes da ES demonstram que estes produtos precisam de processos e etapas diferentes quando comparados ao desenvolvimento de sistemas convencionais [1]. Murphy-Hill et al [1] destacam que os jogos digitais são projetados com um determinado comportamento que intenciona desafiar o jogador, colocando-o em situações com uma dificuldade elaborada e projetada buscando o seu interesse no jogo. As diferentes composições dessas partes de dificuldades buscam garantir que o jogador encontre um desafio adequado ao seu nível de habilidade. A configuração dessas partes, que definem a dificuldade de um jogo digital, intitulamos por Curva de Dificuldade (CD) [2], [3].

Nesse sentido, o ajuste da CD configura-se como uma importante etapa no desenvolvimento e análise dos jogos digitais. [4] exploram a necessidade de eleger um nível de dificuldade ideal de um jogo para o jogador. Neste contexto de experiência do indivíduo, Csikszentmihalyi & Csikszentmihalyi [5] realizaram um estudo que constituiu a teoria da “experiência ótima” na realização das atividades,

a Teoria do *Flow*. Os autores definiram uma relação entre o nível de habilidade de um indivíduo e o esforço necessário para a resolução de uma tarefa. Deste modo, quando estes dois elementos se equivalem, o indivíduo poderia experienciar o “Estado de *Flow*”, momento em que estaria totalmente imerso na realização desta atividade [5].

Em um estudo prévio [6] com o jogo “As Incríveis Aventuras de Apollo & Rosetta no Espaço” (A&R), demonstrou-se um modelo de planejamento para construção de CD estática de um jogo digital. Investigações tem abordado as metodologias voltadas para a geração automática de CD em jogos. [7] descreve a utilização de um modelo relacionado à transformação de informações de entrada (performance do jogador) em uma informação de saída (nova dificuldade a apresentar ao jogador), com gerenciamento de perfis de entidades através de inferência em trilhas. Nesse contexto, [4] também discutem o ajuste da dificuldade de forma dinâmica por meio de agrupamentos de características de desempenho dos jogadores. Já [8] propõem a utilização de funções de avaliação para aprimorar os jogos digitais por meio de dinâmicas populacionais. [9] citam a utilização funções matemáticas para calcular parte de um mecanismo de avaliação de performance de jogadores, enquanto [10] investiga diferentes funções de avaliação com políticas de ajustes para o ajuste dinâmico de jogos.

Neste presente trabalho, o objetivo é criar um modelo para a geração dinâmica de CD, voltado a adaptar a dificuldade do jogo de acordo com o desempenho do jogador em tempo real. A partir de um estudo de caso usando o jogo digital A&R, este trabalho apresenta dois estudos em busca do modelo matemático capaz de adaptar a dificuldade do jogo, criando a CD dinâmica de acordo as habilidades do jogador. Os estudos utilizam diferentes abordagens buscando administrar a relação entre desafio e performance de um jogador em um jogo digital, voltado para geração de CD adaptativa ao contexto do usuário.

## II. CURVA DE DIFICULDADE E A TEORIA DO *FLOW*

O processo de produção de jogos digitais envolve a resolução de diversos elementos pela equipe de desenvolvimento, como a experiência do usuário, usabilidade, jogabilidade, destacando-se o elemento da diversão. Assim, para um jogo ser prazeroso, ele deve manter sua característica lúdica e divertida [11]. Durante o jogo, conforme o jogador avança nos desafios, o elemento CD atua regendo o nível de desafio apresentado. Nesse sentido, Cowley et al. [12] indicam que 1) o jogo deve apresentar diferentes desafios e, ao mesmo tempo, oferecer os meios para o jogador superá-los; 2) a CD deve estabelecer

S. M. Corrêa, Universidade Feevale, Novo Hamburgo, RS, Brasil (e-mail: saulocejrv@gmail.com).

P. R. Santos, Universidade Feevale, Novo Hamburgo, RS, Brasil (e-mail: paulords1994@gmail.com)

B. B. Cerqueira, Universidade Feevale, Novo Hamburgo, RS, Brasil (e-mail: bcerqueira@feevale.br).

J. B. Mossmann, Universidade Feevale, Novo Hamburgo, RS, Brasil (e-mail: mossmann@gmail.com).

D. N. F. Barbosa. Universidade Feevale, Novo Hamburgo, RS, Brasil (e-mail: deboranice@feevale.br).

vínculo entre a habilidade do jogador e os desafios apresentados pelo jogo; e 3) a CD deve apresentar desafios novos e mais complexos considerando o aprendizado anterior do jogador, produzindo assim um equilíbrio entre desafio e habilidades. Tal equilíbrio entre habilidades do jogador e desafios impostos a ele pode ser regido pela teoria do *Flow* [12].

Na teoria do *Flow* [5], o equilíbrio entre os desafios e as habilidades é o que mantém o jogador no canal de fluxo, ou imersão total na atividade. Assim, para que o jogador atinja o estado de fluxo e o mantenha durante a realização da tarefa, essa deve ser ao mesmo tempo desafiadora e realizável. Se a tarefa não é um desafio, torna-se tediosa, porém, se é muito difícil, o jogador frustra-se. Para cada caso, o jogador é levado para fora do canal de fluxo e perde o interesse na tarefa, portanto, a relação entre o desafio e as habilidades do indivíduo é um pré-requisito para a experiência do *Flow*. Logo, na medida em que as habilidades do jogador melhorarem, os desafios devem se tornar mais difíceis, sempre mantendo o equilíbrio entre ambas.

Cowley et al. [12] estuda a experiência de *Flow* sob o ponto de vista de jogos digitais. Segundo a teoria [5], é possível que qualquer pessoa experimente o estado de *Flow* em qualquer atividade, desde que suas habilidades correspondam aos desafios apresentados na proporção certa. Cowley et al. [12] sugerem que uma dessas atividades são os jogos digitais, pois estes jogos fornecem uma atividade que leva o jogador a um estado cognitivo que se aproxima ao estado do *Flow*.

Dentre as abordagens para criação de uma CD, tem-se a modelagem estática e a modelagem dinâmica da dificuldade [13]. Conforme a metodologia *Rational Level Design* (RLD), exemplificada por McMillan [13], a abordagem tradicional de modelagem de dificuldade estática se dá de forma manual, a qual, por meio de testes do protótipo do jogo e análise estatística de acertos e erros, modelos de dificuldade podem ser formados pelo padrão fácil, médio e/ou difícil, por exemplo.

A abordagem de modelagem de ajuste dinâmico baseia-se na mesma concepção: ajustar a dificuldade para manter o jogador no estado de *Flow*, exceto que a modelagem dinâmica busca a adaptação durante a realização da atividade. Dessa forma, no contexto do ajuste de dificuldade dinâmica, o objetivo é fornecer uma entrada para o ajuste dinâmico de dificuldades [14]. Portanto, a partir deste ajuste em tempo real, um modelo matemático que auxilie no cálculo de forma dinâmica se faz necessário, de modo que o programa possa adaptar-se de acordo com os elementos mais fáceis/difíceis para cada jogador.

### III. JOGO PARA ESTIMULAÇÃO COGNITIVA

O jogo Apollo e Rosetta (A&R), é um jogo digital do tipo *exergame* para estimulação das Funções Executivas (FE) em crianças, onde o jogador controla as ações por meio de movimentos corporais. As FE se referem a um grupo de habilidades inter-relacionadas que auxiliam na regulação e controle do comportamento humano para atingir objetivos específicos, divididas em três componentes principais: controle de inibição, memória de trabalho e flexibilidade cognitiva [15].

O jogo possui sete atividades diferentes (minigames) em que o jogador pode explorar diferentes atividades motoras. São propostos 3 tipos de atividades: a) atividades seriadas, em que

os jogadores se acostumam com um tipo de desafio até a atividade quebrar o padrão, exigindo respostas diferentes do habitual; b) atividades com distratores, em que os jogadores devem lidar com as distrações para conseguir avançar nas atividades; c) atividades de controle da resposta motora prepotente, em que o jogador deve inibir uma resposta em automática em curso, para interferir e realizar ações diferentes.

Além disso, armazena informações de identificação e dados referentes a utilização do jogo: atividade e nível jogado, data/hora de uso e performance do jogador. Para validação da CD estática, durante o desenvolvimento foram realizados testes com crianças de 6 a 11 anos, público alvo do jogo “Apollo e Rosetta” [16]. A seguir foi realizado um estudo piloto [6], no qual 7 crianças, sem contato prévio com o jogo, participaram por 32 sessões de 20 minutos, 3 vezes por semana por 3 meses, em ambiente escolar na região do Vale do Rio dos Sinos/RS, totalizando 1528 níveis jogados [6]. Observou-se o comportamento da CD estática e verificou-se uma correlação entre as variáveis *performance* e *sucesso* [6]. De forma geral, a correlação entre a performance e a dificuldade foi positiva: quanto maior a dificuldade, maior também será a performance.

Uma característica fundamental para a utilização deste jogo digital como base de estudo é o componente *CD estática* nele empregado. Buscando uma constante evolução na estimulação das FE, foi desenvolvido nos minigames uma CD estática com dificuldade crescente em relação aos desafios, baseada na teoria do *Flow*. Assim, pensando em um estímulo contínuo para o jogador, as atividades foram organizadas em ciclos incrementais de dificuldade. Cada ciclo possui 9 níveis de jogo, separados em tipos de nível (Normal; Pico; Descanso). Em um ciclo, o primeiro nível possui o menor valor de dificuldade, seguido de 4 níveis de dificuldade crescentes (Normal) até chegar ao pico do ciclo (Pico). Segue-se 3 fases de transição (Descanso), com leve diminuição na dificuldade, voltado ao descanso do jogador após o pico, mantendo-o no estado de *flow* antes de iniciar o próximo ciclo com maior dificuldade.

Ao executar a atividade, o jogador pode avançar para o próximo nível ou não. Esta avaliação, de sucesso ou insucesso na execução, se dá através da performance naquele nível. Se a performance/desempenho for igual ou superior a 70%, o aluno avança um nível, se não, repete o nível atual. Assim, a performance do usuário é medida de acordo com os desafios. O cálculo da dificuldade de cada nível considera um peso (de 0 a 10) para cada mecânica de acordo com a dificuldade de sua realização, definidas *a priori*. Desta forma, é possível verificar o quanto cada mecânica influencia na composição da dificuldade daquele nível. Neste trabalho, tem-se como estudo de caso o projeto da CD desenvolvida na atividade “Desafio dos Opostos Cósmicos”, na qual o objetivo é seguir as instruções para coletar itens que surgem na tela, ou coletar o oposto do que é instruído. A TABELA I apresenta os valores da CD da atividade, na qual a coluna Dificuldade Total é calculada com base em (1):

$$\begin{aligned} \text{Dificuldade} = & (\text{Velocidade} \times 3) + \\ & (\text{Alternância entre mestres} \times 2) + (\text{Física} \times 1) + \\ & (\text{Nome do Objeto} \times 0,5) + (\text{Posição} \times 0,5) + \\ & (\text{Lateralidade} \times 1) + (\text{Partes do Corpo} \times 0,5) + \\ & (\text{Tempo de Resposta} \times 1,5) \end{aligned} \quad (1)$$

TABELA I  
VALORES DAS MECÂNICAS DA ATIVIDADE: DESAFIO DOS OPOSTOS CÓSMICOS – VER (1)

Nível	Velocidade (3)	Alternância mestres (2)	Física (1)	Nome do Objeto (0,5)	Posição (0,5)	Lateralidade (1)	Partes do Corpo (0,5)	Tempo de Resposta (1,5)	Dificuldade Total
1	1	0	2	1	2	1	1	1	9,5
2	1	1	1	1	2	1	1	1	10,5
3	1,1	1	1	2	1	2	1	1	11,8
4	1,1	2	1	2	2	1	2	1	13,8
5	1,2	2	2	2	1	2	2	1	15,6
6	1,2	3	1	2	2	2	2	1,1	17,25
7	1	2	2	2	2	2	2	1	15,5
8	1	2	0	2	2	2	2	1	13,5
9	1	2	1	2	2	2	2	1	14,5

● Nível Normal ● Nível Pico ● Nível Descanso

Na qual: *velocidade* representa a rapidez da atividade, peso 3; *alternância de mestres*, o tipo coleta do item, peso 2; *física* o tamanho dos objetos, peso 1; *nome do objeto* qual item coletar, peso 0,5; *posição* coletar itens acima ou abaixo, peso 0,5; *lateralidade* coletar itens no lado esquerdo ou direito, peso 1; *partes do corpo* coletar com o pé ou mão, peso 0,5; e *tempo de resposta*, o tempo do jogador coletar um item, peso 1,5.

Por fim, pôde-se confirmar que a CD estática planejada comportou-se conforme o esperado, pois conseguiu apresentar desafios mais complexos considerando o aprendizado anterior do indivíduo no jogo, mantendo um equilíbrio cíclico (periódico) entre o desafio e as habilidades das crianças, por meio dos tipos de fase (Descanso, Normal e Pico). Os dados obtidos a partir da aplicação do jogo foram utilizados como cenário para a construção do modelo de geração automática de dificuldades deste trabalho, conforme sugerido por [4].

IV. PROPOSTA DE UM MODELO PARA A GERAÇÃO AUTOMÁTICA DA CURVA DE DIFICULDADE

Esta proposta se baseia em agrupamentos de características de desempenho dos jogadores [4], funções de avaliação com correções por meio de políticas de ajustes [10], dinâmicas populacionais [8] e gerenciamento de perfis de entidades através de inferência em trilhas [7]. Assim, o modelo proposto tem como base de funcionamento a transformação de uma informação de entrada (*performance do jogador*) em uma informação de saída (*nova dificuldade a apresentar ao jogador*). Para alcançar a capacidade de previsão de uma dificuldade, buscou-se uma função matemática, tendo como base os trabalhos de *Tong e Chignell* [9]. Para isso, foi elaborado um modelo estatístico, baseado nos dados de utilização do jogo “Apollo e Rosetta”. O modelo estatístico resultou em uma função matemática, que, quando implementada em um jogo digital pode ser capaz de automatizar a dinâmica de troca de níveis e, assim, a dificuldade enfrentada pelo jogador no jogo em questão.

O modelo aqui proposto é denominado Modelo Gerador de Curva de Dificuldade (MGD). O MGD é um componente acoplado ao jogo, funcionando como um controlador do

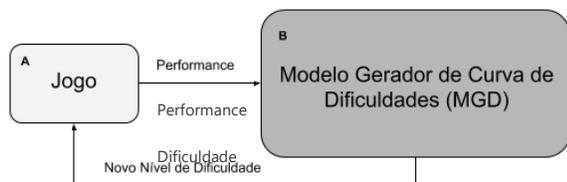


Fig. 1. Visão geral do modelo de geração de curva de dificuldades (MGD).

mecanismo de troca de níveis durante a execução do jogo. A Fig. 1. apresenta a visão geral do modelo.

O primeiro componente (A) é o próprio jogo em que se busca o ajuste dinâmico de dificuldade. Ele deverá ser capaz de fornecer ao segundo componente, o MGD (B), a informação da *dificuldade* do nível junto da *performance* do jogador ao final de cada nível jogado. Como resultado, o MGD retornará ao jogo a informação do próximo *nível*, previsto pelo mecanismo matemático do gerador. Com isso, o jogo pode aplicar ao jogador o nível de dificuldade previsto pelo MGD, que é responsável por gerenciar as relações de reação do jogo com o usuário. Através do estudo estatístico descrito nas próximas páginas, o MGD converte os valores de entrada “*performance e dificuldade*” no valor de saída “*nível previsto*”.

As informações de dificuldade e performance, assim que recebidas no MGD, serão entregues à função de avaliação. Este é o elemento principal da função preditiva do modelo, onde ocorre a conversão dos dados de entrada em um próximo nível a ser jogado, de acordo com a base de dados fornecida ao fim de cada nível jogado. Como resultado da operação da função de avaliação, é obtido o valor relativo ao próximo nível previsto. A Fig. 2. apresenta a estrutura do MGD e o fluxo de dados do gerador.

Com relação ao fluxo de informações entre o jogo e as etapas do modelo, a função de avaliação gera um valor de nível (fase) e pode assumir qualquer valor real. Este valor passa por um segundo elemento antes de o MGD retornar este como resultado do processamento.

Assim, o modelo realimentará o jogo com a informação do *Nível Previsto*. A estrutura do modelo permite que um novo processamento seja executado a qualquer momento, possibilitando que sejam calculados *N* vezes os níveis de dificuldades. A função de avaliação se atualiza a partir da base

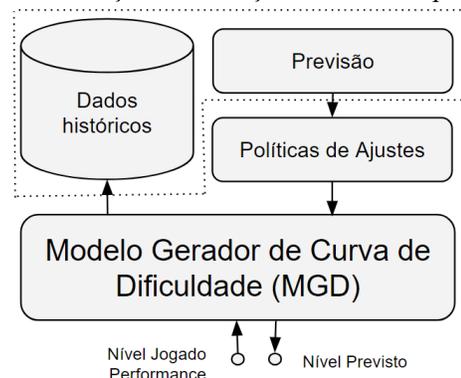


Fig. 2. Fluxo de dados no Gerador de Curva de Dificuldade.

completa dos dados, que é atualizada a cada momento. Dessa forma, o MGD atua automatizando a dinâmica de troca de níveis, cumprindo o objetivo principal do modelo que é a geração automática da CD conforme o contexto do jogador.

### A. Modelo Estatístico Aplicado

Dois modelos estatísticos foram envolvidos no estudo do processo de desenvolvimento da função matemática utilizada no modelo gerador de CD, gerando o Estudo 1 e o Estudo 2. Estes modelos foram desenvolvidos pela necessidade de relacionar e conectar duas grandezas numéricas oriundas do processamento do jogo, no que diz respeito à dificuldade apresentada ao jogador: primeiro, as grandezas de origem, tal qual o nível de dificuldade em que o jogador jogou a última atividade e a performance que ele obteve no nível em questão. A segunda grandeza numérica é a dificuldade ou nível para o qual se deseja direcionar o jogador, baseado na performance obtida no nível jogado.

Como a intenção é obter um crescimento constante no nível de dificuldade e de desafio apresentado ao jogador, busca-se uma função que ligue estas grandezas, mas também que apresente um resultado que proporcione suavidade na transição. Com o primeiro estudo estatístico (Estudo 1), foi levantada uma função de ligação que cumpriu com a necessidade de estabelecer relação entre as grandezas. Dessa forma, o objetivo foi atendido, entretanto, a transição não se mostrou suave, o que gera uma experiência brusca de trocas de níveis. Isso gerou a necessidade de uma nova exploração nos dados de utilização do jogo. A partir dessa nova exploração, obteve-se o Estudo 2. Este segundo estudo apresentou flexibilidade em determinar o nível que o aluno vai jogar e automatizar a escolha do nível a partir da performance dele. Através do ajuste de um modelo de efeito misto [17], foi possível prever o nível que o aluno irá jogar a partir da relação entre dificuldade e performance.

#### 1) Estudo 1

Baseado na análise de utilização do jogo “Apollo e Rosetta”, observou-se que há uma correlação entre a dificuldade apresentada em um nível e a performance obtida por um aluno ao jogar. Assim, para modelar o grau de dificuldade do jogo a partir da performance, foram utilizados Modelos Lineares Generalizados com Efeito Misto [17] buscando analisar a relação entre uma variável resposta e uma ou mais variáveis explicativas, para identificar uma função que a descreva.

Como a variável *dificuldade* apresenta uma distribuição assimétrica e é estritamente positiva, foi utilizada regressão *Gama* com efeitos aleatórios ao nível do jogo tanto no *intercepto* quanto na *inclinação*. O efeito aleatório no *intercepto*

capta o nível médio de dificuldade de cada nível, enquanto o efeito aleatório na *inclinação* visa individualizar o efeito da performance sobre a dificuldade.

Para encontrar o melhor modelo estatístico capaz de prever a dificuldade a partir da performance, foram ajustadas 12 regressões *Gama* com efeitos aleatórios ao nível do jogo (*intercepto* e *inclinação*), variando a função de ligação e a forma de trabalhar com a performance. Foram utilizadas três funções de ligação (*identidade*, *logarítmica* e *quadrática*), sendo que para cada uma foram ajustados 4 modelos com transformações sobre a variável performance. Para selecionar o melhor modelo, foram avaliados a medida de qualidade do ajuste (AIC) [18] e o  $R^2$ . Assim, os modelos foram ajustados tanto para o banco de dados completo, quanto para o banco de dados contendo apenas a primeira tentativa de cada jogador, sendo que o segundo apresentou um melhor ajuste. Optou-se por apresentar apenas os modelos ajustados para o banco de dados da primeira tentativa. Nos cálculos e análises estatísticas, utilizou-se o *software* estatístico *R Studio* (versão 3.2.4).

Na TABELA III pode-se verificar o ajuste das 12 regressões *Gama* com efeitos aleatórios ao nível do jogo tanto no *intercepto* quanto na *inclinação*, variando a função de ligação e a forma de trabalhar com a performance. O efeito aleatório na *inclinação* (variável performance) foi testado a partir do teste da razão de verossimilhança, sendo que, quando não significativo, não foi mantido no modelo. O desvio padrão ( $\sigma$ ) do efeito aleatório ilustra o quanto irá variar o coeficiente  $\beta$  para cada jogo. Quando o desvio padrão ( $\sigma$ ) do efeito aleatório não foi apresentado é por que não foi significativo o efeito aleatório naquele nível.

Avaliando todos os modelos ajustados, o que apresentou o menor AIC e o maior  $R^2$  foi o modelo 2 com função de ligação logarítmica. A partir dele foi possível verificar que conforme a medida da performance aumenta, a dificuldade também

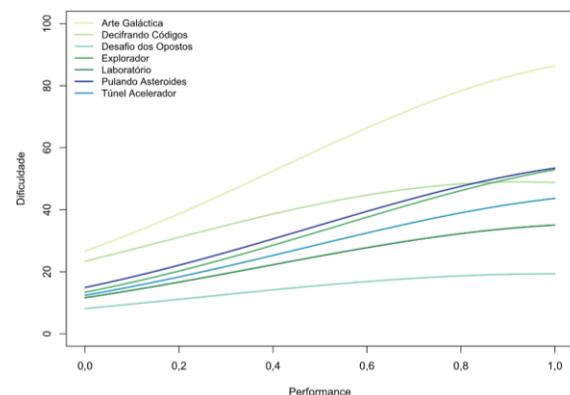


TABELA II  
EQUAÇÕES UTILIZADAS NAS FUNÇÕES DE LIGAÇÃO

Função de Ligação	Modelo	Equação
Identidade	1	$E(\text{Dificuldade}) = (20,147 + \beta_i) + (31,957 + \alpha_i) \times \text{Performance}$
	2	$E(\text{Dificuldade}) = (17,269 + \beta_i) + (41,978 + \alpha_i) \times \text{Performance} - 7,810 \times \text{Performance}^2$
	3	$E(\text{Dificuldade}) = (15,816 + \beta_i) + (51,034 + \alpha_i) \times \text{Log}(\text{Performance})$
	4	$E(\text{Dificuldade}) = (17,806 + \beta_i) + (41,041 + \alpha_i) \times \text{Log}(\text{Performance}) + 11,082 \times \text{Log}(\text{Performance})^2$
Logarítmica	1	$E(\text{Dificuldade}) = \exp\{3,119 + \beta_i + (0,723 + \alpha_i) \times \text{Performance}\}$
	2	$E(\text{Dificuldade}) = \exp\{2,686 + \beta_i + (1,982 + \alpha_i) \times \text{Performance} - 0,866 \times \text{Performance}^2\}$
	3	$E(\text{Dificuldade}) = \exp\{2,966 + \beta_i + (1,253 + \alpha_i) \times \text{Log}(\text{Performance})\}$
	4	$E(\text{Dificuldade}) = \exp\{2,673 + \beta_i + (2,434 + \alpha_i) \times \text{Log}(\text{Performance}) + 1,139 \times \text{Log}(\text{Performance})^2\}$
Quadrática	1	$E(\text{Dificuldade}) = \{(4,666 + \beta_i) + (2,381 + \alpha_i) \times \text{Performance}\}^2$
	2	$E(\text{Dificuldade}) = \{(4,018 + \beta_i) + 4,413 \times \text{Performance} + (-1,475 + \alpha_i) \times \text{Performance}^2\}^2$
	3	$E(\text{Dificuldade}) = \{(4,221 + \beta_i) + (4,011 + \alpha_i) \times \text{Log}(\text{Performance})\}^2$
	4	$E(\text{Dificuldade}) = \{(4,065 + \beta_i) + 4,779 \times \text{Log}(\text{Performance}) + (-0,820 + \alpha_i) \times \text{Log}(\text{Performance})^2\}^2$

TABELA III  
REGRESSÕES GAMA COM EFEITOS ALEATÓRIOS

Função de Ligação	Fonte	Efeito Fixo			Efeito Aleatório	R <sup>2</sup>	AIC		
		$\beta$	E.P. ( $\beta$ )	Valor-p	$\sigma$				
Identidade	Modelo 1	Intercepto	20,147	5,590	0,000	6,21	42,57%	10113,58	
		Performance	31,957	8,273	0,000	9,26			
	Modelo 2	Intercepto	17,269	5,976	0,004	6,41	42,64%		
		Performance	41,978	10,547	0,000	9,14			
	Modelo 3	Performance <sup>2</sup>	-7,810	6,836	0,253	-	42,60%		
		Intercepto	15,816	5,579	0,005	6,33			
	Modelo 4	Log(Performance)	51,034	11,585	0,000	14,73	42,58%		
		Intercepto	17,806	5,487	0,001	6,09			
		Log(Performance) <sup>2</sup>	11,082	11,906	0,352	-			
	Modelo 1	Intercepto	3,119	0,198	0,000	0,25	42,57%		10114,61
		Performance	0,723	0,175	0,000	0,24			
	Modelo 2	Intercepto	2,686	0,003	0,000	0,27	42,92%		
Performance		1,982	0,003	0,000	0,25				
Performance <sup>2</sup>		-0,866	0,003	0,000	-				
Modelo 3	Intercepto	2,966	0,215	0,000	0,27	42,66%	10111,26		
	Log(Performance)	1,253	0,289	0,000	0,39				
Modelo 4	Intercepto	2,673	0,003	0,000	0,29	42,83%			
	Log(Performance)	2,434	0,003	0,000	0,41				
	Log(Performance) <sup>2</sup>	-1,139	0,003	0,000	-				
Modelo 1	Intercepto	4,666	0,004	0,000	0,65	42,59%	10112,63		
	Performance	2,381	0,004	0,000	0,72				
Modelo 2	Intercepto	4,018	0,609	0,000	0,61	42,81%			
	Performance	4,413	0,992	0,000	-				
	Performance <sup>2</sup>	-1,475	0,817	0,071	0,53				
Modelo 3	Intercepto	4,221	0,566	0,000	0,68	42,67%	10111,03		
	Log(Performance)	4,011	0,943	0,000	1,14				
Modelo 4	Intercepto	4,065	0,637	0,000	0,62	42,75%			
	Log(Performance)	4,779	1,577	0,002	-				
	Log(Performance) <sup>2</sup>	-0,820	1,848	0,657	1,22				

aumenta, sendo que o aumento tende a se estabilizar devido ao fato de haver um termo quadrático negativo no modelo (conforme Fig. 3). Na TABELA II é possível verificar as equações dos modelos ajustados, apresentados na TABELA III.

A seguir, pode-se verificar o resultado do ajuste do modelo 2 com função de ligação logarítmica variando por jogo (Fig. 3.) e o resultado do modelo para a atividade Desafio dos Opostos Cósmicos (Fig. 4.). A Fig. 4. mostra a aplicação da função de ligação logarítmica, aplicado ao contexto de configurações da atividade. Esta curva possui a característica de um aumento constante na dificuldade, ao passo que a performance também aumenta. Assim, um novo estudo estatístico foi realizado, buscando desenvolver uma nova função que apresente um comportamento mais próximo do comportamento da curva estática já existente no jogo.

## 2) Estudo 2

Neste estudo, a relação entre dificuldade e performance foi estabelecida a partir da criação de uma nova variável dada por  $Dificuldade \times \ln(Performance \times 100)$ . O logaritmo neperiano foi colocado na fórmula para suavizar o impacto da performance sobre o deslocamento ao longo dos níveis. A seguir, foi utilizado um modelo linear misto, dada a relação distinta em cada atividade do nível com a nova variável criada. Foram inseridos efeitos aleatórios tanto no *intercepto* quanto no coeficiente de inclinação (efeito da nova variável criada sobre

o nível da atividade). Sendo assim, existe um coeficiente  $\beta_i$  adicionado ao intercepto para cada atividade e um coeficiente  $\gamma_i$  adicionado à estimação de inclinação para cada atividade. Dessa forma, propõe-se a seguinte equação:

$$E(Nível) = \{(\beta_0 + \beta_i) + (\gamma_0 + \gamma_i) \times Dificuldade \times \ln(Performance \times 100)\} \quad (2)$$

Na qual  $i$  equivale a  $i$ -ésima atividade, com  $i=1, \dots, 7$ .

Os efeitos fixos  $\beta_0$  e  $\gamma_0$  são as estimativas populacionais, que valem para todas as atividades, enquanto que os efeitos aleatórios são representados por  $\beta_i$  e  $\gamma_i$ , que variam por atividade, sendo o efeito aleatório um reflexo da heterogeneidade natural entre as atividades. Por fim, também foram avaliados o AIC [18] e o R<sup>2</sup> do modelo. Na TABELA IV, pode-se verificar o ajuste da regressão linear com efeitos aleatórios ao nível da atividade no intercepto e na variável  $Dificuldade \times Performance$ , com o logaritmo neperiano da performance multiplicada por 100 (visto que o resultado da performance varia entre 0 a 1). Na Eq. (3) pode-se verificar o modelo ajustado, conforme a TABELA IV.

$$E(Nível) = (-8,385 + \beta_i) + (0,143 + \gamma_i) \times Dificuldade \times \ln(Performance \times 100) \quad (3)$$

Com o modelo mencionado, é possível permitir uma flexibilidade em determinar o nível que será jogado e também automatizar a escolha do nível a partir da performance, o que

TABELA IV  
REGRESSÃO LINEAR E COM EFEITOS ALEATÓRIOS AO TIPO DE JOGO NO INTERCEPTO

Fonte	Efeito Fixo			Efeito Aleatório $\sigma$	R <sup>2</sup>	AIC
	$\beta$	E.P. ( $\beta$ )	Valor-p	Minigame		
Intercepto	-8,385	1,413	0,001	3,715	97,0%	5062,31
Dificuldade*ln(Performance*100)	0,143	0,032	0,004	0,085		

não era possível anteriormente, uma vez que o aluno só passava para um nível superior se apresentasse uma performance maior que 70%, caso contrário, permaneceria no mesmo nível. Com esse modelo, o aluno poderá ir para o nível mais avançado se tiver tido um excelente desempenho, como poderá voltar para níveis anteriores se tiver tido um desempenho muito ruim.

Dessa forma, o objetivo da função será prever o nível que o aluno irá jogar a partir da relação entre dificuldade e performance de forma flexível, e automatiza a escolha do nível a partir da performance do aluno, o que não era possível com a CD estática.

## V. APLICAÇÃO DO MODELO PROPOSTO E RESULTADOS

### A. Exemplo e Aplicação do Modelo Proposto

Para aplicar o modelo proposto foi realizada uma simulação da utilização de um minigame por um jogador fictício. Na abordagem utilizada, os dados de performance podem ser escolhidos de forma arbitrária, com a finalidade de experimentar a aplicação do modelo matemático em um ambiente controlado. Por exemplo, um jogador joga o nível 1 de uma atividade, obtém uma nota, a nota é aplicada no MGD e então é obtido uma previsão para o próximo nível, com maior ou menor dificuldade. Considerando que o valor seja válido e coerente com o progresso esperado, a atividade passa então a operar com este novo nível. A seguir, o jogador procede para um nível previsto pelo modelo.

Inicia-se então a segunda iteração: O jogador joga a fase atual (a fase prevista após iteração 1) e obtém um novo valor de performance, relativa a este nível. O jogo então encaminhará as duas informações ao modelo, que irá processar este funcionamento sucessivamente, enquanto estiver em execução.

O modelo converterá os parâmetros de entrada em um valor previsto para o próximo nível que o jogador deve jogar. O valor é observado e as regras aplicadas (definidas como o elemento Política de Ajustes, conforme sugerido por [9]), assim como na iteração 1. Caso identifique-se alguma incoerência do valor

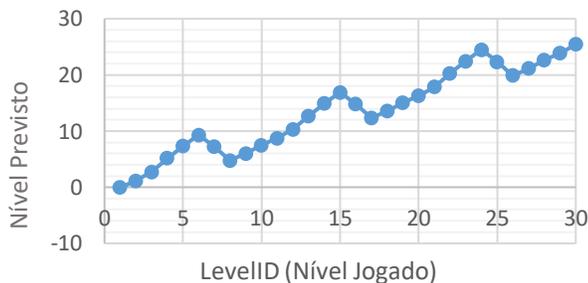


Fig. 5. Ajuste do modelo 2 com função de ligação logarítmica – Performance do jogador em 70%.

obtido com o esperado pelo projeto da atividade neste ponto, o valor é alterado pelo modelo e só então devolvido ao jogo, completando a segunda iteração.

Quando ocorre alguma discrepância entre o valor previsto pelo modelo matemático e os níveis da atividade, o elemento Política de Ajustes opera analisando o valor, baseado em regras determinadas para a atividade específica, na qual se é aplicado o MGD. Neste ponto surgem as regras para o elemento Políticas de Ajuste, a partir da necessidade de normalizar o resultado da função, em algum eventual dado não desejado. Estas regras,

elencadas a seguir, foram definidas a partir da análise do retorno da função matemática aplicada isoladamente.

- **Regra 1** – Sendo o retorno da função negativo, o valor é alterado para o número do nível atual. Por exemplo: o resultado da função matemática apresenta um valor negativo. Como não há possíveis níveis cujo valor seja menor que zero, quando o retorno da função é negativo, o valor é alterado para o valor do nível atual. Neste caso, o jogador mantém-se na fase que jogou.

- **Regra 2** – Para evitar uma condição sem saída (*loop*) nos níveis iniciais, caso o nível jogado seja menor que quatro (<4), o resultado do modelo será o próprio nível mais um (Nível Jogado + 1) para uma performance menor que 70%, e o próprio nível menos um (Nível Jogado - 1) para uma performance maior ou igual a 70%.

- **Regra 3** – É definida para evitar que o jogador repita os níveis já jogados. Assim, caso o nível previsto seja algum nível já jogado e que o jogador já tenha passado com mais de 70% de performance, soma-se 1 ao nível previsto.

Para levantar as questões que foram consideradas na elaboração das regras da Política de Ajustes, os dados foram organizados supondo que um jogador fosse submetido à aplicação do modelo descrito, contendo apenas o modelo estatístico ativo. Baseado no comportamento de retorno do modelo matemático, foram elencadas as regras que modificam o retorno, para aprimorar o resultado da aplicação do modelo ao jogo. Assim, foram dispostos trinta níveis de dificuldade da CD estática, demonstrados na Fig. 5. e aplicada em (4). Os níveis referidos são a suposição de que um jogador inicie uma partida no nível 1, passando de nível a cada jogada com uma pontuação de 70% de performance.

$$E(\text{Nível}) = (-8,385 - 3,186) + (0,143 + 0,142) \times \text{Dificuldade} \times \ln(\text{Performance} \times 100) \quad (4)$$

Após a definição das regras para a Política de Ajustes, foi elaborada uma simulação utilizando todas as regras. Esta simulação resultou na Fig. 6., que apresenta cada uma das 18

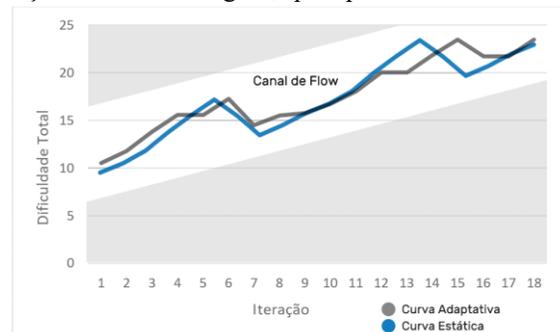


Fig. 6. Curva gerada para um jogador simulado em Desafio dos Opostos.

iterações geradas pelo modelo com um jogador fictício, utilizando resultados oriundos de jogadores de um estudo piloto prévio [6], em comparação a CD estática definida para a atividade previamente. Por fim, o modelo resultante é composto por uma base de dados oriunda de um jogo que possui uma dinâmica preexistente de dificuldades, um elemento preditivo, composto por uma função matemática e, por fim, uma política de ajustes, em que pôde-se prever regras que, quando aplicadas, manipulam o retorno do modelo. A dificuldade indica a possibilidade de manter o jogador no estado de *flow*, e demonstra que o crescimento dos desafios se distribui ao longo

do tempo, revelando uma curva com característica de crescimento semelhante ao apresentado na teoria do *flow*.

## VI. CONCLUSÕES

Este artigo apresentou um modelo conceitual para a geração automática de CD (MGD), gerando uma técnica para alcançar o ajuste dinâmico de CD no contexto de um jogo digital. Para demonstrar a aplicabilidade da proposta, realizou-se um experimento utilizando o modelo proposto com aplicação em uma das atividades do jogo digital Apollo & Rosetta. Na aplicação, foi possível perceber o funcionamento e a relação entre os elementos do modelo. Ressalta-se a necessidade de definições pré-existentes de dificuldade para o jogo/atividade (Ver Eq. 1 e TABELA I).

Um conjunto de dados obtidos previamente foi subsídio para a geração do modelo estatístico preditivo, elemento principal do modelo. Assim, apesar da necessidade de utilização de uma base de dados onde o jogo já possui definições de CD prévia, nota-se que a aplicação deste modelo torna uma CD (estática) variável no seu funcionamento, de acordo com o desempenho do usuário. O modelo permite, ainda, a atualização da função matemática, reconfigurada a partir da atualização da base de dados de jogo, visto que variam na medida em que o jogador interage com os níveis. A integração do modelo proposto não apenas substitui a CD estática já existente em um jogo, mas utiliza a curva estática para personalizar a experiência do jogador no jogo. Como trabalhos futuros, pretende-se aplicar o jogo digital Apollo & Rosetta com o MGD em operação com jogadores do público alvo em tempo real, de forma que se possa analisar e validar o comportamento e eficiência do modelo em diferentes cenários além dos simulados neste estudo.

## AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001. Agradecemos também ao CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) e a Universidade Feevale pelo apoio e suporte para esta pesquisa.

## REFERÊNCIAS

- [1] E. Murphy-Hill *et al.*, “Cowboys, ankle sprains, and keepers of quality: How is video game development different from software development?” in *Proc. 36th Int. Conf. Softw. Eng.*, 2014, pp. 1-11.
- [2] S. Natkin, *Video games and interactive media: A glimpse at new digital entertainment*. Florida, EUA: CRC Press, 2006.
- [3] E. Byrne, *Game Level Design (Vol. 6)*. Rockland, MA: Charles River Media, Inc., 2004.
- [4] O. Missura, T. Gärtner, “Player modeling for intelligent difficulty adjustment,” in *Int. Conf. Discov. Sci.*, Springer., pp. 197-211, 2009.
- [5] M. Csikszentmihalyi, I. Csikszentmihalyi, *Flow: The Psychology of Optimal Experience*, NY: Harper Row, 1990.
- [6] J. Mossman *et al.*, “The Planning of Difficulty Curves in an Exergame for Inhibitory Control stimulation in a school intervention program: a pilot study,” *Front. Psy.*, vol. 10, pp. 2271, 2019.
- [7] A. Wagner, “Um Modelo para Gerenciamento de Perfis de Entidades Através de Inferência em Trilhas,” M.S thesis, Dept. App. Comp., Unisinos, São Leopoldo, Brazil, 2013.
- [8] G. Kendall and G. Whitwell, “An evolutionary approach for the tuning of a chess evaluation function using population dynamics” in *Proc. 2001 Con. Evol. Comp.*, 2001, pp. 995–1002.
- [9] T. Tong, M. Chignell, “Developing a serious game for cognitive assessment: choosing settings and measuring performance,” in *Proc. 2nd I. Symp. Chi. CHI. ACM*, pp. 70-79, 2014.

- [10] R. Hunnicke, “The case for dynamic difficulty adjustment in games,” in *ACM SIGCHI Inter. Conf. Adv. Comp. Entert. Tech.*, 2005.
- [11] R. Koster, *Theory of fun for game design*, Sebastopol, CA, EUA: O'Reilly Media, Inc, 2013.
- [12] B. Cowley *et al.*, “Toward an understanding of flow in video games,” *Comp. Ent. (CIE)*, vol. 6, no. 2, pp. 20, 2008.
- [13] L. McMillan, “The Rational Design Handbook: An Intro to RLD,” Gamasutra, 2013. [Online]. Disponível em: [http://www.gamasutra.com/blogs/LukeMcMillan/20130806/197147/The\\_Rational\\_Design\\_Handbook\\_An\\_Intro\\_to\\_RLD.php](http://www.gamasutra.com/blogs/LukeMcMillan/20130806/197147/The_Rational_Design_Handbook_An_Intro_to_RLD.php), Acesso: Ago., 2021.
- [14] O. Missura, “Dynamic Difficulty Adjustment,” Ph.D. dissertation, Inf. Inst., Universität Bonn, Germany, 2015.
- [15] A. Diamond, “Executive Functions,” *A. Rev. Psy.*, vol. 64, pp. 135, 2013.
- [16] J. Mossman *et al.*, “Evaluation of the usability and playability of an exergame for executive functions stimulation and its development process,” in *Int. Conf. Eng. Psy. Cog. Erg.*, Vancouver, 2017, pp. 164-179.
- [17] G. M. Fitzmaurice *et al.*, *Applied Longitudinal Analysis*, NJ, EUA: John Wiley & Sons, 2011.
- [18] H. Akaike, “Information theory and an extension of the maximum likelihood principle,” in *Sel. Papers of H. A.* NY, EUA, 1998, pp. 199-213.



**SAULO MARCOS CORRÊA** é nascido em Novo Hamburgo, RS, Brasil. É Bacharel em Ciências da Computação pela Universidade Feevale em 2018 e Técnico em Eletrônica pela Fundação Liberato em 2009. Atua na área de análise e desenvolvimento de sistemas.



instituição.

**PAULO RICARDO DOS SANTOS** nasceu em Novo Hamburgo, RS, Brasil. Atualmente é graduando do curso de Letras na Universidade Feevale. Desde 2015 é bolsista e assistente de pesquisa na Universidade Feevale. Atua na área de ensino, realizando estágio docente na



atualmente é produtor e designer de jogos digitais em turno integral na Universidade Feevale.

**BERNARDO B. CERQUEIRA** nasceu em São Leopoldo, RS, Brasil. Doutorando e Mestre em Diversidade Cultural e Inclusão Social na Universidade Feevale (2019). Tecnólogo em Jogos Digitais pela Universidade Feevale (2012). Foi assistente de pesquisa no Laboratório de Objetos de Aprendizagem (LOA) e



**JOÃO B. MOSSMANN** Doutor em Informática na Educação pela Universidade Federal do Rio Grande do Sul (UFRGS - 2018). Mestre em Ciência da Computação pela Pontifícia Universidade Católica do Rio Grande do Sul (PUCRS - 2011). Bacharel em Ciência da Computação (Universidade Feevale -

2007). Diretor do Instituto de Ciências Criativas e Tecnológicas (ICCT) na Universidade Feevale, e professor nos cursos de Ciência da Computação e no Mestrado de Indústria Criativa.



**DÉBORA N. F. BARBOSA** é Doutora e Mestre em Ciência da Computação pela Universidade Federal do Rio Grande do Sul (UFRGS - 2007, 2001). Bacharel em Análise de Sistemas pela Universidade Católica de Pelotas (UCPel - 1998). Pós-doutora pela University of California, Irvine, EUA. Bolsista de Produtividade em Desenvolvimento Tecnológico e Extensão Inovadora - DT - nível 1D do CNPq. É professora titular na Universidade Feevale, atuando como professora permanente do PPG em Diversidade Cultural e Inclusão Social (PPGDiver) e cursos de bacharelado na área da computação.