

NCCGen: Um Gerador de Cartas Criativas para o Jogo Digital Hearthstone por meio de Redes Neurais Artificiais Recorrentes

Arthur Martins de Medeiros*

Luís Fabrício Wanderley Góes†

Pontifícia Universidade Católica de Minas Gerais, Depto. de Ciência da Computação, Brasil

RESUMO

A modelagem de artefatos de um jogo, como habilidades e magias, é ainda um processo manual que consome tempo e requer muita criatividade dos *game designers*. Particularmente, efeitos de cartas, atributos e mecânicas são artefatos centrais da jogabilidade de um jogo digital de cartas colecionáveis (DCCG). Por exemplo, se um conjunto de cartas não está balanceado, é muito provável que o jogo se torne tedioso e pouco interessante. Neste artigo é proposto o uso de uma rede neural artificial recorrente, para gerar automaticamente cartas criativas para o DCCG Hearthstone. De acordo com a área da criatividade computacional, um artefato criativo precisa ser novo e possuir valor. No intuito de verificar a criatividade das cartas geradas neste artigo, foi aplicado um questionário para jogadores do Hearthstone. Os resultados mostraram que 76% dos jogadores concordam que as cartas geradas fazem sentido, e 47% concordam com a novidade das cartas. Além disso, utilizando-se a métrica RDC para avaliação de criatividade, as cartas alcançaram até 1.51 de criatividade em uma escala de 0 a 2.

Palavras-Chave: Game Design, Criatividade Computacional, Jogos Digitais de Cartas Colecionáveis.

1 INTRODUÇÃO

A criatividade computacional é uma área de pesquisa que estuda a criação de algoritmos para a geração automática pela máquina de artefatos criativos, tais como músicas, jogos, poesias e arte [2][1]. Um artefato é considerado criativo quando ele é novo e possui valor dentro de um determinado contexto. Por exemplo, a IBM tem gerado receitas culinárias criativas combinando uma base de dados, que inclui ingredientes e receitas existentes, algoritmos evolucionários e métricas de avaliação de novidade e sabor [14]. Um dos maiores obstáculos da criatividade computacional, é o fato de que a criatividade é significativa apenas quando a percepção humana está presente. Um sistema criativo que não possui um componente cognitivo humano para fins de avaliação não é eficiente, por não ser capaz de saber se o artefato gerado é criativo ou não [15].

Esta área utiliza-se ainda de diversas técnicas de inteligência artificial para a geração destes artefatos criativos, tais como as redes neurais artificiais ou *deep learning*. Recentemente a empresa Google propôs um algoritmo baseado em redes neurais convolucionais, capaz de aprender e vencer vários jogos do antigo videogame “Atari”, apresentando em mais de 75% dos jogos o desempenho de um jogador profissional [10]. Este tipo de solução propicia que computadores possam gerar comportamento e artefatos que até então eram apenas gerados por humanos.

O objetivo deste trabalho é a proposta de um gerador de cartas criativas para jogo Hearthstone por meio de redes neurais artificiais recorrentes(RNN), chamado NCCGen. O Hearthstone é um jogo

de cartas no estilo DCCG (Digital Collectible Card Game) lançado pela empresa Blizzard Entertainment. Normalmente o processo de criação de cartas de um jogo não é simples, pois as próprias cartas possuem regras que fazem o jogo ser balanceado. Tem-se então a preocupação em manter o equilíbrio do jogo ao gerar novas cartas. A fim de tentar resolver e minimizar a complexidade de criação de cartas para o jogo Hearthstone, neste trabalho é utilizada uma rede neural recorrente, para reconhecer padrões de uma base de dados composta por cartas do jogo e gerar novas cartas. A criatividade das cartas criadas neste trabalho foram avaliadas por jogadores do Hearthstone através de um questionário online.

Este artigo está estruturado em 5 seções. A seção 2 apresenta os trabalhos relacionados ao tema deste artigo. A seção 3 descreve o sistema proposto, explicando seu propósito e funcionalidade. Os resultados experimentais são apresentados na seção 4, e por fim, a seção 5 apresenta a conclusão do trabalho.

2 TRABALHOS RELACIONADOS

Esta seção descreve os principais trabalhos relacionados ao trabalho proposto neste artigo. Em [9] foi realizado um experimento com uma RNN, que foi alimentada com uma base de dados que possuía toda a obra de Shakespeare em um arquivo de texto. A ideia principal desse experimento era que, alimentando a rede com essa base, a rede neural seria capaz de gerar uma saída com textos que teriam o estilo de Shakespeare. As amostras retiradas da saída revelaram que não houve erros de inglês nas frases e palavras, no entanto, nem todo o texto produzido fez sentido. O presente trabalho utiliza a mesma implementação de uma rede neural recorrente utilizada em [9] para geração de cartas do jogo Hearthstone.

Seguindo este mesmo método, em [11] foi testado o mesmo algoritmo, em uma base de dados que possuía todas as cartas do jogo de cartas Magic the Gathering, com o propósito de tentar gerar novas cartas que fizessem sentido para o jogo. Nos primeiros resultados era possível claramente perceber uma relação entre uma carta gerada e uma carta já existente no jogo. No entanto, as próximas iterações do algoritmo geraram saídas com resultados mais satisfatórios, com sugestões de novas habilidades para as cartas e sem cometer muitos erros de gramática. Neste experimento, o autor faz algumas poucas alterações no comportamento e processo de criação de amostras do sistema criado em [9]. É possível por exemplo especificar que todos os nomes de cards gerados deverão começar com “Kor”. O jogo MTG possui regras parecidas com o Hearthstone, mas possui algumas diferenças que tornam o experimento mais complexo. O recurso de mana no MTG funciona basicamente com quatro tipos diferentes, e a maioria das cartas tem ou não que utilizar de algum desses quatro tipos, para que seja pago seu custo. Além disso, o recurso de mana é gerenciado através de cartas que são capazes de gerar esse recurso para o jogador. Em contrapartida, o Hearthstone não tem esse tipo de processo para gerenciar a mana, a cada turno é acrescido em um à reserva de mana do jogador, e essa mana é única, podendo ser utilizada para qualquer tipo de carta.

Em [12] foi realizado um estudo relacionado à geração de música procedural, para soundtracks de jogos digitais. Esse estudo teve como objetivo testar se o que é conhecido como *Experience-Driven*

*e-mail: arthur.medeiros@hotmail.com

†e-mail: lfwoes@pucminas.br

Procedural Content Generation (EDPCG) é capaz de reduzir significativamente a ansiedade e frustração de jogadores durante o jogo. Para isso foi desenvolvida uma biblioteca para uma linguagem de programação chamada Pure Data¹, que é utilizada para processamento e geração de áudio, vídeo, gráficos 2D e 3D. Algumas das métricas importantes definidas nesse estudo compreendem o cálculo da frustração, o planejamento do jogador, e o perigo. O perigo, por exemplo, é calculado de acordo com uma distância média entre o jogador e inimigos.

Um outro trabalho utilizando RNN foi desenvolvido pelo grupo *Deep Mind*. Um mecanismo denominado DRAW (*Deep Recurrent Attentive Writer*) é capaz de gerar imagens complexas de um modo similar com o que uma pessoa utilizaria para fazer algum desenho, criando primeiro um rascunho e aos poucos melhorando esse rascunho até se tornar um desenho final. O mecanismo DRAW é um par de redes neurais recorrentes artificiais. A primeira parte é um codificador que comprime a imagem durante o treinamento da rede neural, e a segunda parte é o decodificador que reconstitui as imagens como saídas do algoritmo [6]. Um processo similar é utilizado neste trabalho, uma vez que a rede neural recorrente gera cadeias de caracteres codificados como saída durante o processo de treinamento, e logo após é necessário decodificar cada amostra utilizando um outro algoritmo.

Em [3] é apresentado um trabalho utilizando algoritmos evolucionários para automatizar a criação de jogos de cartas baseados no estilo Blackjack² e UNO³. Nesse trabalho é desenvolvido uma gramática livre de contexto, para gerar uma linguagem descritiva para jogos de cartas, ou seja, cada palavra na linguagem representa um conjunto de características e especificações que definem um jogo de cartas. Essa gramática foi utilizada por programação genética orientada a gramática, que aplica os processos de mutação, cruzamento e seleção em uma população fixa inicial de indivíduos. Vale ressaltar a modelagem de uma função *fitness* para avaliar diferentes objetivos como, checar se os jogos são jogáveis, se os jogos não possuem regras muito fortes (torna o jogo difícil de ser jogado), balanceamento e habilidades diferenciadas.

Um estudo aprofundado sobre Redes Neurais Recorrentes é feito em [7]. Nesse estudo o objetivo é descobrir se existem arquiteturas capazes de superar a performance de uma RNN, mais especificamente, um tipo de RNN denominado *The Long Short-Term Memory* (LSTM). Através de testes em diferentes arquiteturas, alterando parâmetros, foi encontrada uma arquitetura que supera a performance da LSTM e da recentemente descoberta *Gated Recurrent Unit* (GRU). Um ponto muito relevante sobre os resultados desse trabalho é que foi notado que a LSTM utilizada crescendo em um *bias*, superou a própria LSTM e a GRU na maioria das tarefas.

Finalmente em [5], um sistema de criatividade computacional chamado HoningStone foi proposto. Esse sistema gera automaticamente combos de cartas para o jogo *Hearthstone* baseado na Teoria do Aprimoramento de Criatividade, ao invés de criar novas cartas. O HoningStone utilizou uma métrica criativa baseada na surpresa bayesiana e eficiência para gerar e avaliar os combos.

3 NCCGEN

NCCGen é um sistema baseado em redes neurais recorrentes para a geração de cartas criativas para o jogo *Hearthstone*. O *Hearthstone* é um jogo digital de cartas colecionáveis, em que cada jogador cria o seu próprio baralho de cartas baseado em um conjunto de cartas que o jogador possui. Existem dois tipos principais de cartas: lacaio (*minion*); e magia (*spell*). As magias podem ter efeitos como: causar dano em algum lacaio; fortalecer um lacaio de seu controle; ou até mesmo aumentar os pontos de vida.

¹<http://puredata.info/>

²<http://www.wopc.co.uk/history/blackjack/blackjack>

³<http://www.wonkavator.com/uno/unohistory.html>

Diferentemente das redes neurais artificiais comuns, as redes neurais artificiais recorrentes são capazes de trabalhar com sequências de vetores arbitrários. Além disso a RNN mantém um vetor de ativações para cada iteração, o que torna o modelo mais complexo [7]. O NCCGen utiliza uma RNN, passando como entrada um bloco de texto. Baseado neste bloco de texto a RNN é capaz de gerar a distribuição de probabilidade de um próximo caractere, dado um conjunto prévio de caracteres. A cada iteração a rede será capaz de prever um novo caractere [8].

Se o NCCGen recebe como entrada os caracteres “s”, “p”, “e”, “l”, o sistema irá prever que “l” será o próximo caractere para fazer a palavra *spell*. Ao longo das iterações, o sistema é capaz de compor associações mais complexas, sendo capaz por exemplo de reconhecer quando se deve dar poder de ataque e defesa para uma carta (apenas quando se tratar de um lacaio) [13].

Na figura 1 é mostrada (a) uma carta do tipo lacaio e (b) uma magia. É possível observar que uma carta é composta dos atributos: custo de mana; ataque; e defesa, sendo os dois últimos apenas pertencentes aos lacaios. As cartas possuem um nome e também um texto que descreve os efeitos e mecânicas da carta. Por exemplo, a carta na figura 1(b) é uma magia que permite ao jogador escolher um lacaio que está em jogo, e a qualquer momento em que esse lacaio atacar, será restaurado 4 pontos de vida do herói do jogador. Ao projetar uma carta, um ponto importante é o balanceamento, ou seja, o custo de mana das cartas deve ser justo, de acordo com os efeitos de carta. Por exemplo, uma carta que possui como efeito causar 10 pontos de dano a um lacaio, não pode custar 1 de mana, senão ela poderia desbalancear o jogo. Ainda se alterarmos os valores e criar uma carta que pode causar 1 ponto de dano a um lacaio, com o custo de mana 10, essa seria uma carta totalmente desbalanceada e não útil.



Figura 1: Exemplo de duas cartas do jogo *Hearthstone*.

O NCCGen gera cartas criativas utilizando-se da abordagem proposta em [11], para geração de cartas do jogo *Magic The Gathering*. Para alimentar a rede neural é necessária uma base de cartas existentes do jogo, que foi obtida pelo website *hearthstone-jason*⁴. Este conjunto de cartas no formato JSON foi convertido em um formato de entrada adequado para a rede neural. A RNN funciona procurando padrões no arquivo de entrada, portanto, para que cada um dos atributos da carta tivesse um padrão diferenciado, foi utilizada a representação apresentada na tabela 1. Um exemplo de uma entrada representando a carta da Figura 1(a) pode ser observada a seguir:

@ShrinkMeister | *^/^* | **Battlecry:** Give a minion -2 Attack this turn. | {1} | #7#

⁴hearthstonejson.com

Resposta	Valor
Concordo Completamente	1
Concordo Parcialmente	0.8
Não Concordo mas Não Discordo	0.6
Discordo Parcialmente	0.4
Discordo Completamente	0.2

Tabela 3: Valores representativos para cada afirmação.

seja completamente ou parcialmente, é de 43%. Os outros 10% escolheram a opção neutra. É importante ressaltar que os perfis dos jogadores que responderam ao questionário pode variar de iniciante até jogador mais experiente, considerando que esse questionamento não foi feito aos participantes.

A criatividade pode ser avaliada como uma combinação entre novidade e valor. Em [4] foi proposta uma métrica chamada *Regent Dependent Creativity* (RDC) que avalia a criatividade de artefatos gerados combinando valor e novidade. Neste trabalho nós utilizamos esta métrica para avaliar a criatividade das cartas geradas, baseadas nas respostas do questionário. A equação 1 foi utilizada para calcular a criatividade das 5 cartas apresentadas neste artigo.

$$rdc(a) = n_a + v_a - |n_a - v_a| \quad (1)$$

onde:

a : artefato (carta) em avaliação.

rdc_a : métrica RDC de criatividade.

v_a : valor medido pelas respostas da afirmação “Essa carta faz sentido”.

n_a : novidade medida pelas respostas da afirmação “Essa carta é diferente das que eu conheço”.

O valor RDC pode variar de [0,2]. Nesse caso, foi necessário converter a escala das respostas para os valores descritos na tabela 3 para calcular n_a e v_a . A figura 2 mostra que o RDC das cartas foi maior do que 1, ou seja, quando mais próximo de 2, mais criativas são as cartas geradas. A carta 3 alcançou RDC de 1.51, sendo a carta gerada mais criativa.

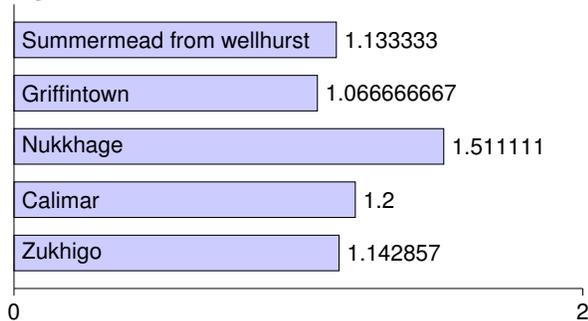


Figura 2: Avaliação da criatividade utilizando a métrica RDC.

5 CONCLUSÃO

Este trabalho apresentou o uso de uma rede neural artificial recorrente para geração de cartas do jogo Hearthstone. Conforme revelado nos resultados experimentais, a rede neural mostrou eficiência na geração de saídas com poucos erros de inglês e mantendo a estrutura da representação de uma carta. Um questionário aplicado a jogadores de Hearthstone revelou que mais de 50% dos jogadores concordaram que as cartas geradas são diferentes das cartas que já existem. Além disso, utilizando-se a métrica RDC para avaliação de criatividade, as cartas alcançaram até 1.51 de criatividade em uma escala de 0 a 2. No entanto, apesar dos resultados positivos, vale ressaltar que a quantidade de jogadores que participaram do

questionário foi baixa, o que impossibilita uma conclusão estatisticamente relevante.

Futuramente este trabalho pode ser utilizado para gerar cartas que serão disponibilizadas em um website, para que jogadores de Hearthstone possam avaliar as cartas que foram geradas e sugerirem melhorias nas cartas. Este *feedback* dos jogadores pode ser utilizado para ajustar os parâmetros de entrada como: temperatura; número de nodos; e números de camadas em trabalhos futuros com o objetivo de otimizar os resultados. Por fim, a medida em que o jogo Herathstone lançar novas cartas, é possível aumentar a base de entrada e melhorar os resultados já alcançados.

6 AGRADECIMENTOS

Nós gostaríamos de agradecer ao FIP PUC Minas, FAPEMIG, CNPq e CAPES por nos apoiar neste trabalho.

REFERÊNCIAS

- [1] M. A. Boden. *The creative mind myths and mechanisms*. London New York: Routledge, 2004.
- [2] S. Colton and G. A. Wiggins. Computational creativity: The final frontier? *European Conference on Artificial Intelligence*, pages 21–26, 2012.
- [3] J. M. Font, T. Mahlman, D. manrique, and J. Togelius. Towards the automatic generation of card games through grammar-guided genetic programming. *International Conference on the Foundations of Digital*, pages 360–363.
- [4] C. França, L. F. W. Góes, Álvaro Amorin, R. Rocha, and A. R. da Silva. Regent-dependent creativity: A domain independent metric for the assessment of creative artifacts. In *International Conference on Computational Creativity (ICCC)*, 2016.
- [5] L. F. W. Goes, A. R. da Silva, J. Rezende, A. Amorim, C. Franca, T. Zaidan, B. Olimpio, L. Ranieri, H. Morais, S. Luana, and C. A. P. S. Martins. Honingstone: Building creative combos with honing theory for a digital card game. *IEEE Transactions on Computational Intelligence and AI in Games*, PP(99):1–1, 2016.
- [6] K. Gregor, I. Danihelka, A. Graves, D. j. Rezende, and D. Wierstra. Draw: A recurrent neural network for image generation. *CoRR*, 2015.
- [7] R. Jozefowicz, W. Zaremba, and I. Sutskever. An empirical exploration of recurrent network architectures. In *Proceedings of the 32nd International Conference on Machine Learning*, volume 37, 2015.
- [8] A. Karpathy. The unreasonable effectiveness of recurrent neural networks, 2015. Disponível em <http://karpathy.github.io/2015/05/21/rnn-effectiveness/>.
- [9] A. Karpathy, J. Johnson, and L. Fei-Fei. Visualizing and understanding recurrent networks. *CoRR*, 2015.
- [10] D. Kumaran and D. Hassabis. From pixels to actions: Human-level control through deep reinforcement learning, 2015. Disponível em: <http://googleresearch.blogspot.com.br/2015/02/from-pixelsto-actions-human-level.html>.
- [11] R. M. Milewicz. Generating magic cards using deep, recurrent neural networks, 2015. Disponível em <http://www.mtgsalvation.com/forums/creativity/custom-cardcreation/612057-generating-magic-cards-using-deep-recurrent-neural>.
- [12] E. Plans, D. Morelli, and D. Plans. Audionode : Prototypical affective modelling in experience-driven procedural music generation. In *Workshop on Computational Creativity on Games (CCG)*, 2015.
- [13] S. Prickett. Teaching a computer to work magic, 2015. Disponível em <http://weldbham.com/blog/2015/08/12/teaching-a-computer-to-work-magic/>.
- [14] L. Varshney, F. Pinel, K. Varshney, A. Schorgendorfer, , and Y. Chee. Cognition as a part of computational creativity. *International Conference on Cognitive Informatics and Cognitive Computing*, pages 36–43, 2013.
- [15] L. R. Varshney, F. Pinel, K. R. Varshney, A. Schorgendorfer, and Y.-M. Chee. Cognition as a part of computational creativity. In *IEEE Int. Conf. on Cognitive Informatics and Cognitive Computing*, pages 36–43, 2013.