

Modelagem baseada em *sketches* suportadas por Redes Adversárias Generativas (GANs)

Vinícius Luis Trevisan de Souza

João Paulo Gois

Centro de Matemática, Computação e Cognição (CMCC)

Universidade Federal do ABC (UFABC)

{vinicius.trevisan,joao.gois}@ufabc.edu.br

Abstract: O presente trabalho em andamento propõe o uso de Redes Adversárias Generativas (*Generative Adversarial Networks – GANs*) para modelagem tridimensional interativa de esboços bidimensionais (*sketches*). Essa abordagem é uma alternativa às técnicas clássicas de modelagem baseada em *sketch*, feitas a partir de conceitos de Processamento Geométricos e propriedades de percepção visual.

1. Introdução

Com a evolução das GPUs, que trouxe grande poder computacional para computadores pessoais, tornou-se viável o uso de métodos que utilizam técnicas de aprendizado de máquinas para as mais diversas tarefas que exigem interatividade.

Neste sentido, o presente trabalho de pesquisa em andamento abordará o problema de design e implementação de um sistema interativo que permita a modelagem de objetos 3D a partir de técnicas de esboços utilizando redes pré-treinadas por algoritmos de aprendizado.

2. Redes Adversárias Generativas (GANs)

As Redes Adversárias Generativas, propostas por Goodfellow [3], têm dois componentes principais: um discriminador, que é treinado para distinguir um conjunto de dados de entrada (*input*) real de um falso; e um gerador, que cria conjuntos de dados falsos semelhantes aos reais a partir de uma entrada de ruído.

A ideia principal é que o gerador crie um conjunto de dados e envie para o discriminador, que por sua vez tenta categorizar essa entrada como verdadeira ou falsa.

Em cada iteração o discriminador recebe dados reais (*ground-truth*) e os dados criados pelo gerador. O discriminador acerta sempre que categorizar a entrada real como "verdadeira" e a entrada que veio do gerador como "falsa". Se o discriminador erra, ele se corrige para ficar mais assertivo numa próxima iteração (Fig. 1).




Fig. 1. Esquema de treinamento para uma GAN de imagens. O Discriminador recebe imagens criadas pelo Gerador a partir de ruído e também recebe imagens reais

Por outro lado, o gerador precisa criar conjuntos de dados tão próximos ao real que levem o discriminador a classificá-los como verdadeiros. Essa é a natureza adversária da rede, os componentes competem e ficam mais especializados a partir de mais iterações do treinamento.

Finalmente, o gerador treinado pode ser usado para criar conjuntos de dados quase indistinguíveis dos reais, como imagens [6].

3. Trabalhos Relacionados

A modelagem *sketch-based* não é um assunto recente em computação gráfica [5], mas o uso de inteligência artificial para essa modelagem começou a ser explorado mais recentemente, com a evolução das GPUs e sua popularização.

Uma das formas de se reconstruir uma imagem 3D utilizando GANs pode ser utilizando o gerador treinado para receber como entrada um esboço 2D e gerar nuvens de pontos como saída (Fig. 2) [1] e então utilizar técnicas de reconstrução de superfícies a partir dessa nuvem de pontos [8].



Fig. 2. Reconstrução de modelos 3D a partir de nuvens de pontos. Fonte: [1]

Alternativamente, pode-se utilizar técnicas de separação de partes, em que cada nuvem de pontos é especializada em criar uma parte semanticamente diferente da figura, como por exemplo a asa e a cauda de um avião [2].

Existem abordagens mais sofisticadas, que consistem em utilizar o espaço latente das GANs treinadas e extrair seus vetores para reconstruir formas utilizando um *autoencoder* volumétrico (Fig. 3) [4, 7, 9].




Fig. 3. Reconstrução de modelos 3D a partir de vetores do espaço latente da GAN. Fonte: [7]

Essas técnicas são o estado-da-arte da reconstrução 3D utilizando inteligência artificial.

4. Referências

- [1] Achlioptas, P., Diamanti, O., Mitliagkas, I., Guibas, L. Learning representations and generative models for 3d point clouds. *International conference on machine learning. PMLR*, 2018.
- [2] Gal, R., Bermano, A., Zhang, H., and Cohen-Or, D. (2020). MRGAN: Multi-Rooted 3D Shape Generation with Unsupervised Part Disentanglement. *CoRR abs/2007.12944* (2020)
- [3] Goodfellow, I. J. Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. C., and Bengio, Y. Generative adversarial nets. *NIPS*, 2014.
- [4] Liu, J., Yu, F., and Funkhouser, T. (2017, October). Interactive 3D modeling with a generative adversarial network. *2017 International Conference on 3D Vision (3DV)* (pp. 126-134). *IEEE*.
- [5] Olsen, L., Samavati, F. F., Sousa, M. C., Jorge, J. A. (2009). Sketch-based modeling: A survey. *Computers & Graphics*, 33(1), 85-103.
- [6] Radford, A., Metz, L., Chintala, S. Unsupervised representation learning with deep convolutional generative adversarial networks *ICLR (Poster)*, 2016.
- [7] Wang, L., Qian, C., Wang, J., Fang, Y. (2018, October). Unsupervised learning of 3d model reconstruction from hand-drawn sketches. In *Proceedings of the 26th ACM international conference on Multimedia* (pp. 1820-1828).
- [8] Wang, X., Xu, Y., Xu, K., Tagliasacchi, A., Zhou, B., Mahdavi-Amiri, A., Zhang, H. PIE-NET: Parametric Inference of Point Cloud Edges. *CoRR abs/2007.04883* (2020)
- [9] Wu, J., Zhang, C., Xue, T., Freeman, B., and Tenenbaum, J. (2016). Learning a probabilistic latent space of object shapes via 3d generative-adversarial modeling. *Advances in neural information processing systems* (pp. 82-90).