



## TRANSFORMANDO ESBOÇOS ARQUITETÔNICOS EM VISUALIZAÇÕES REALISTAS: Uma abordagem com CycleGAN

**Kevin Camargo<sup>1</sup>; Janaína Faustino Leite<sup>2</sup>;**

### RESUMO

Este artigo explora o desenvolvimento de um modelo CycleGAN voltado para converter esboços de fachadas arquitetônicas modernistas em imagens com visualização mais refinada. O projeto utiliza dois conjuntos de dados distintos: um com esboços arquitetônicos e outro com fotos de projetos desenvolvidos em aplicativos de modelagem 3D. O modelo foi treinado no Google Colab com TensorFlow e ajustado para melhorar a qualidade das representações aprimoradas. A avaliação do desempenho utilizou o Índice de Similaridade Estrutural (SSIM). Espera-se que os resultados demonstrem o potencial do modelo para criar visualizações detalhadas, contribuindo para a comunidade de Inteligência Artificial e promovendo avanços na geração de imagens.

### Palavras-chave:

Conversão de Imagens; Redes Generativas Adversariais; Visualização Arquitetônica; Redes Neurais;

### 1. INTRODUÇÃO

Apresentado por Goodfellow et al. (2014), as Redes Generativas Adversariais (GANs) são modelos de Inteligência Artificial que propõem uma abordagem baseada em dois componentes principais: o gerador (G) e o discriminador (D). Neste modelo, o gerador cria dados sintéticos e os submete ao discriminador, cuja função é discernir entre dados reais e falsificados. Essa estratégia foi aplicada com sucesso em conjuntos de dados de imagens, sobre os quais o gerador cria imagens simuladas e as submete ao discriminador para avaliar sua autenticidade.

Segundo Aguiar (2023), observa-se uma crescente demanda por projetos arquitetônicos com alto nível de realismo. No entanto, a renderização de tais modelos frequentemente desafia os profissionais devido à sua complexidade e à necessidade de resultados visualmente autênticos. Embora ferramentas de renderização possam produzir resultados de alta qualidade, explorar o desenvolvimento de uma rede generativa especializada pode resultar em uma alternativa promissora, com potencial para entregar resultados comparáveis. Nesse contexto, o presente estudo propõe o desenvolvimento de um modelo GAN especializado na geração de imagens de fachadas residenciais realistas.

O objetivo principal é criar imagens que reproduzam com alta fidelidade o aspecto final de um projeto, com base em sua modelagem inicial. A eficácia do modelo será avaliada mediante a comparação entre as imagens geradas e as imagens reais dos projetos finalizados, utilizando a

---

<sup>1</sup>Discente do Curso de Ciência da Computação, IFSULDEMINAS – *Campus* Passos. E-mail: kevin.camargotecinfo@gmail.com

<sup>2</sup>Orientador, IFSULDEMINAS – *Campus* Passos. E-mail: janaina.leite@ifsuldeminas.edu.br

métrica Índice de Similaridade Estrutural (SSIM) como parâmetro para identificar a similaridade entre ambas as representações visuais

## 2. FUNDAMENTAÇÃO TEÓRICA

### 2.1 Redes Generativas Adversariais (GANs)

O funcionamento das GANs pode ser dividido em etapas. Inicialmente, o gerador recebe como entrada vetores de ruídos, que servem como base para a produção de amostras sintéticas. O discriminador, por sua vez, recebe tanto amostras reais quanto sintéticas e tenta classificá-las corretamente. Ao decorrer do treinamento, a função de perda do gerador detalhada pela Equação 2.1 visa maximizar a probabilidade de o discriminador cometer um erro ao classificar as amostras geradas como reais. Por outro lado, a função de perda do discriminador detalhada pela Equação 2.2 busca minimizar essa probabilidade, incentivando-o a distinguir corretamente entre amostras reais e sintéticas. A cada iteração os pesos referentes às estruturas são alterados a fim de buscar a evolução do modelo

$$LG = E_{z \sim p(z)}[\log D(G(z))] \quad (2.1)$$

$$LD = (E_{x \sim p_{data}(x)} \log D(x)) + E_{z \sim p(z)}[\log(1 - D(G(z)))] \quad (2.2)$$

### 2.2 CycleGan

As GANs tradicionalmente utilizam *datasets* pareados para o treinamento, nos quais cada imagem de entrada está associada a uma imagem de saída correspondente. No entanto, as CycleGANs buscam resolver esse problema ao permitir a tradução de imagens entre dois domínios diferentes sem a necessidade de pares correspondentes. Elas utilizam um ciclo de consistência, no qual a imagem é traduzida para o outro domínio e, em seguida, revertida ao seu domínio original, garantindo que a tradução preserve a estrutura e as características essenciais da imagem inicial (Chen, et al., 2022).

O processo de tradução nas CycleGANs envolve converter uma imagem de um domínio A para um domínio B com um gerador treinado e, em seguida, traduzir essa imagem de volta para o domínio A com outro gerador. A imagem resultante é comparada com a original para garantir a preservação das características iniciais (Zhu et al., 2017). O ciclo de consistência é essencial para que o modelo mantenha as principais características dos domínios durante a tradução, o que permite o uso de *datasets* não pareados e facilita a aplicação da CycleGAN em cenários onde imagens correspondentes são difíceis de obter, ampliando a flexibilidade e a eficiência do treinamento.

### 3. MATERIAL E MÉTODOS

Inicialmente, para a realização desta pesquisa, dois *datasets* distintos foram desenvolvidos, visando o treinamento e a avaliação do sistema proposto. O primeiro *dataset* será composto por uma coleção de imagens representando esboços arquitetônicos, selecionados de forma a abranger projetos com diferentes graus de realismo. O segundo *dataset*, por sua vez, incluiu imagens de casas modernistas resultantes do trabalho em programas de modelagem arquitetônica. Ambos *datasets* contém aproximadamente mil e duzentas imagens que serão divididos em dois diretórios: um destinado ao treino, contendo 75% das imagens coletadas, e outro para validação, contendo os 25% restantes. Essa divisão ocorre para verificar se o modelo está apenas decorando as amostras de treino ou se é capaz de generalizar de forma eficaz, evidenciando sua verdadeira capacidade de gerar imagens realistas.

Após a finalização dos *datasets*, foi iniciada a construção do modelo utilizando a plataforma online Google Colab como base para o treinamento. O modelo foi desenvolvido na linguagem Python, empregando o framework TensorFlow e considerando a arquitetura CycleGAN. Esse ambiente de desenvolvimento foi escolhido por sua facilidade de uso e capacidade de processamento, permitindo um treinamento eficiente e escalável do modelo.

### 4. RESULTADOS PARCIAIS

O modelo se encontra em uma fase intermediária de treinamento e ajustes, gerando resultados iniciais promissores. Em duas imagens obtidas até o momento, é possível notar avanços na transformação dos esboços arquitetônicos em representações mais detalhadas. A figura 1 traz uma visualização lado a lado entre a versão inicial da estrutura, enquanto a segunda metade produzida pelo modelo já revela uma composição um pouco mais próxima das características pretendidas. Esses resultados sugerem que o modelo está evoluindo gradualmente, embora ainda precise de ajustes para alcançar uma visualização mais refinada.

Figura 01: Resultado Parcial obtido



Fonte: Autoria própria

## 5. CONCLUSÃO

Caso a viabilidade seja atestada, os resultados obtidos poderão incentivar a adoção de projetos semelhantes em outras áreas da arquitetura, como design de interiores, e até mesmo em campos distintos, ampliando as aplicações da técnica desenvolvida. Além disso, espera-se que os *datasets* desenvolvidos possam ser adicionados a plataformas de pesquisa para que possam ser utilizados para outros fins. Isso contribuirá com a comunidade de Inteligência Artificial, facilitando o avanço de técnicas de aprendizado de máquina e redes neurais generativas.

## REFERÊNCIAS

AGUIAR, A. A. **Arquitetura Digital: análise comparativa entre programas computacionais de modelagem e renderização**. 2023. f. 55. Trabalho de Conclusão de Curso (Graduação) – Universidade Federal de Alagoas, Arapiraca.

CHEN, K. et al. An Automatic Defect Detection System for Petrochemical Pipeline Based on Cycle-GAN and YOLO v5. *Sensors*, v. 22, p. 7907–7938, 2022

GOODFELLOW, Yan. et al. Generative Adversarial Nets. **Advances in Neural Information Processing Systems**, v. 27, p. 2672–2680, 2014

ZHU, J.-Y. et al. Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks. In: IEEE INTERNATIONAL CONFERENCE ON COMPUTER VISION (ICCV). [S.l.: s.n.], 2017. p. 2242–2251.