



UNIVERSIDADE FEDERAL DO CEARÁ
CAMPUS RUSSAS
CURSO DE GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

MARIA JOSIVÂNIA OLIVEIRA PINHEIRO

**DESAFIOS NA UTILIZAÇÃO DE TÉCNICAS DE RENDERIZAÇÃO NÃO
FOTORREALISTAS COM TRANSFERÊNCIA DE ESTILO COM CARACTERÍSTICAS
DO *CARTOON*: UMA REVISÃO SISTEMÁTICA DA LITERATURA**

RUSSAS

2023

MARIA JOSIVÂNIA OLIVEIRA PINHEIRO

DESAFIOS NA UTILIZAÇÃO DE TÉCNICAS DE RENDERIZAÇÃO NÃO
FOTORREALISTAS COM TRANSFERÊNCIA DE ESTILO COM CARACTERÍSTICAS DO
CARTOON: UMA REVISÃO SISTEMÁTICA DA LITERATURA

Trabalho de Conclusão de Curso apresentado ao
Curso de Graduação em Ciência da Computação
do Campus Russas da Universidade Federal do
Ceará, como requisito parcial à obtenção do
grau de bacharel em Ciência da Computação.

Orientador: Prof. Dr. Rafael Fernandes
Ivo

RUSSAS

2023

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

P721d Pinheiro, Maria Josivânia Oliveira.
Desafios na utilização de técnicas de renderização não fotorrealistas com transferência de estilo com características do cartoon: uma revisão sistemática da literatura / Maria Josivânia Oliveira Pinheiro. – 2023.
62 f. : il. color.

Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Campus de Russas,
Curso de Ciência da Computação, Russas, 2023.
Orientação: Prof. Dr. Rafael Fernandes Ivo.

1. Renderização não fotorrealistic. 2. Cartoon. 3. Transferência de estil. 4. Revisão sistemática da literatura. I. Título.

CDD 005

MARIA JOSIVÂNIA OLIVEIRA PINHEIRO

DESAFIOS NA UTILIZAÇÃO DE TÉCNICAS DE RENDERIZAÇÃO NÃO
FOTORREALISTAS COM TRANSFERÊNCIA DE ESTILO COM CARACTERÍSTICAS DO
CARTOON: UMA REVISÃO SISTEMÁTICA DA LITERATURA

Trabalho de Conclusão de Curso apresentado ao
Curso de Graduação em Ciência da Computação
do Campus Russas da Universidade Federal do
Ceará, como requisito parcial à obtenção do
grau de bacharel em Ciência da Computação.

Aprovada em: 17/07/2023.

BANCA EXAMINADORA

Prof. Dr. Rafael Fernandes Ivo (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Markos Oliveira Freitas
Universidade Federal do Ceará (UFC)

Profa. Dra. Tatiane Fernandes Figueiredo
Universidade Federal do Ceará (UFC)

Prof. Dr. Alexandre Matos Arruda
Universidade Federal do Ceará (UFC)

AGRADECIMENTOS

Agradeço primeiramente a Deus, pois Ele é quem me dá força e coragem para nunca desistir, mesmo diante das dificuldades.

Aos meus pais, minha gratidão, que sempre acreditaram no meu esforço e nunca desanimaram, mesmo nos momentos em que eu mesma me senti desmotivada.

Ao meu orientador, Rafael Ivo, por ter aceitado a importante tarefa de me guiar neste trabalho. Agradeço por sua paciência e por ter aguentado minha ansiedade em querer resolver tudo rapidamente. Suas orientações e conhecimento compartilhado contribuíram significativamente para o desenvolvimento deste trabalho.

Aos meus amigos, em especial ao meu amigo Ionésio, que esteve ao meu lado desde o primeiro momento da graduação. Sua presença e apoio constantes me ajudaram a superar desafios e celebrar conquistas.

Agradeço a todos que direta ou indiretamente contribuíram para a realização deste trabalho. A todos, muito obrigada!

“Nossas dúvidas são traidoras e nos fazem perder o que, com frequência, poderíamos ganhar, por simples medo de arriscar.”

(William Shakespeare)

RESUMO

A renderização não fotorrealística (NPR) ou estilizada é uma técnica desenvolvida ao longo dos anos que, em contraste à síntese de imagens realista, propõe a geração de imagens ou vídeos de cenas 3D, com traços específicos que comunicam a ideia de uma ilustração concebida à mão. Essa aplicação está em expansão, comum às áreas de computação gráfica e processamento de imagem, com intuito de esclarecer os princípios e conceitos de vários métodos contendo diferenças no estilo e aparência visual. Contudo, apesar dos avanços, existe uma escassez de trabalhos que apresentem o estado da arte do tema proposto. Portanto, este trabalho tem como objetivo realizar uma revisão sistemática da literatura sobre técnicas de renderização não fotorrealística que utilizam redes adversárias generativas para a transferência de estilo com características de *cartoon*. Reconhecemos que essas técnicas estão em constante evolução, portanto, identificar trabalhos que abordem esse tema pode ser útil para os pesquisadores que desenvolvem novas soluções. No desenvolvimento deste trabalho, foi estabelecido um planejamento metodológico, que resultou na análise de 16 artigos relevantes. Esses artigos foram analisados, permitindo assim responder às questões de pesquisa estabelecidas. Os resultados obtidos apontam que essas técnicas estão se tornando cada vez mais promissoras para a área, porém, ainda existem desafios a serem superados, tais como a captura precisa das características desejadas, a preservação de detalhes, o controle preciso do nível de estilização desejado e a eficiência computacional para renderizações em tempo real. Com base nos resultados obtidos, os pesquisadores podem direcionar seus esforços para superar os desafios mencionados e desenvolver novas soluções mais eficientes e eficazes.

Palavras-chave: renderização não fotorrealística; *cartoon*; transferência de estilo; revisão sistemática da literatura.

ABSTRACT

Non-Photorealistic Rendering (NPR) or stylized rendering is a technique that has been developed over the years, which, in contrast to realistic image synthesis, aims to generate images or videos of 3D scenes with specific features that convey the idea of a hand-drawn illustration. This application is expanding, common to the fields of computer graphics and image processing, with the purpose of clarifying the principles and concepts of various methods that exhibit differences in style and visual appearance. However, despite the advancements, there is a scarcity of works that present the state of the art on the proposed topic. Therefore, this work aims to conduct a systematic literature review on non-photorealistic rendering techniques that utilize generative adversarial networks for style transfer with cartoon characteristics. We acknowledge that these techniques are constantly evolving, so identifying works that address this topic can be useful for researchers developing new solutions. In the development of this work, a methodological planning was established, resulting in the analysis of 16 relevant articles. These articles were examined, thus allowing for the answering of the established research questions. The obtained results indicate that these techniques are becoming increasingly promising for the field, however, there are still challenges to be overcome, such as the accurate capture of desired characteristics, detail preservation, precise control of the desired level of stylization, and computational efficiency for real-time renderings. Based on the obtained results, researchers can direct their efforts towards overcoming the mentioned challenges and developing new, more efficient and effective solutions.

Keywords: non-photorealistic rendering; cartoon; style transfer; systematic literature review.

LISTA DE FIGURAS

Figura 1 – Imagem Realista (à esquerda) versus Renderização Não Fotorrealística (NPR) (à direita)	15
Figura 2 – Um <i>cartoon</i> de um cientista louco estereotipado.	17
Figura 3 – Figura de um desenho técnico.	17
Figura 4 – Gráfico de dispersão.	17
Figura 5 – Técnica de pintura artística.	17
Figura 6 – Ilustração dos eixos x e y para representar uma imagem digital	20
Figura 7 – a) 4-vizinhança; b) 4-diagonal; c) 8-vizinhança.	21
Figura 8 – Matrizes para Filtragem de uma imagem. (a) - Imagem original. (b) - Imagem com filtro passa baixa. (c) - Imagem com Filtro passa alta. (d) - Imagem com Filtro passa alta com melhoramento de contraste	22
Figura 9 – Exemplo da aplicação de segmentação com limiarização usando diferentes valores de limiar para o tom de cinza	23
Figura 10 – A imagem (c) foi gerada a partir da combinação do conteúdo da imagem (a) e do estilo da imagem (b).	24
Figura 11 – Exemplo de uma arquitetura <i>Generative Adversarial Network</i> (GAN).	25
Figura 12 – Exemplo de tradução de imagem para imagem	27
Figura 13 – Aplicação de GANs na área da saúde	27
Figura 14 – Exemplo de tradução de imagem para imagem	28
Figura 15 – Resultados de transferência de estilo de desenho animado	29
Figura 16 – Passos para realização de uma revisão sistemática da literatura	31
Figura 17 – Fluxograma do processo de seleção dos artigos disponíveis na base de dados <i>Google acadêmico</i>	35
Figura 18 – Imagem de entrada à esquerda, resultado da técnica à direita	37
Figura 19 – Imagem de entrada à esquerda, resultado da técnica à direita	38
Figura 20 – Imagem de entrada à esquerda, resultado da técnica à direita	39
Figura 21 – Imagem de entrada à esquerda, resultado da técnica à direita	40
Figura 22 – Imagem de entrada à esquerda, resultado da técnica à direita	41
Figura 23 – Imagem de entrada à esquerda, resultado da técnica à direita	41
Figura 24 – Imagem de entrada à esquerda, resultado da técnica à direita	42
Figura 25 – Imagem de entrada à esquerda, resultado da técnica à direita	43

Figura 26 – Imagem de entrada à esquerda, resultado da técnica à direita	44
Figura 27 – Imagem de entrada à esquerda, resultado da técnica à direita	45
Figura 28 – Imagem de entrada à esquerda, resultado da técnica à direita	45
Figura 29 – Imagem de entrada à esquerda, resultado da técnica à direita	46
Figura 30 – Imagem de entrada à esquerda, resultado da técnica à direita	47
Figura 31 – Imagem de entrada à esquerda, resultado da técnica à direita	49
Figura 32 – Resultados da técnica.	52
Figura 33 – Resultado da técnica.	52
Figura 34 – Resultado da técnica.	52
Figura 35 – Resultado da técnica.	52
Figura 36 – Métricas utilizadas pelos autores	53
Figura 37 – Resultado de um teste de ablação.	54
Figura 38 – Combinação das métricas utilizadas pelos autores para maximizar a avaliação	54
Figura 39 – Exemplo de um resultado indesejável por conter evidências de artefatos visuais fora do conteúdo original da imagem.	55
Figura 40 – Exemplos de distorção e não preservação de detalhes.	55
Figura 41 – Exemplo de um resultado desejável com bordas limpas e harmoniosas. . . .	57
Figura 42 – Exemplos de detecção de saliência na imagem.	57
Figura 43 – Exemplo de produção de ruídos na região da testa.	57

LISTA DE QUADROS

Quadro 1 – Comparativo dos trabalhos relacionados e o proposto.	30
Quadro 2 – Questões de pesquisas	33
Quadro 3 – Critérios de Inclusão (CI)	34
Quadro 4 – Critérios de Exclusão (CE)	34
Quadro 5 – Relação das métricas utilizadas pelos autores.	50

LISTA DE ABREVIATURAS E SIGLAS

CNN	<i>Convolutional Neural Networks</i>
FID	<i>Fretchet Inception Distance</i>
GAN	<i>Generative Adversarial Network</i>
IS	<i>Inception Score</i>
NPR	<i>NonPhotorealistic Rendering</i>
SSIM	<i>Structural Similarity</i>

SUMÁRIO

1	INTRODUÇÃO	15
1.1	Objetivos	18
<i>1.1.1</i>	<i>Objetivo geral</i>	<i>18</i>
<i>1.1.2</i>	<i>Objetivos específicos</i>	<i>18</i>
2	FUNDAMENTAÇÃO TEÓRICA	19
2.1	Renderização Não Fotorrealística	19
2.2	Imagem Digital	19
2.3	Filtragem	20
2.4	Segmentação de imagem	21
2.5	Transferência de estilo de imagens	22
2.6	Redes Adversárias Generativas	24
3	TRABALHOS RELACIONADOS	26
3.1	<i>Image-to-image translation: Methods and applications</i>	<i>26</i>
3.2	<i>Applications of Generative Adversarial Networks (GANs): An Updated Review</i>	<i>26</i>
3.3	<i>Neural Style Transfer: A Critical Review</i>	<i>28</i>
3.4	<i>Cartoon Image Processing: A Survey</i>	<i>28</i>
3.5	O presente trabalho	29
4	METODOLOGIA	31
4.1	Planejamento	32
<i>4.1.1</i>	<i>Objetivo e identificação de uma necessidade de revisão</i>	<i>32</i>
<i>4.1.2</i>	<i>Definindo o protocolo</i>	<i>32</i>
<i>4.1.2.1</i>	<i>Questões de pesquisa</i>	<i>32</i>
<i>4.1.2.2</i>	<i>Estratégia de busca dos estudos</i>	<i>33</i>
<i>4.1.2.3</i>	<i>Elaboração da String de Busca</i>	<i>33</i>
<i>4.1.2.4</i>	<i>Critérios de inclusão e exclusão</i>	<i>33</i>
<i>4.1.2.5</i>	<i>Avaliação do protocolo</i>	<i>34</i>
4.2	Condução	35
5	ESTUDOS SELECIONADOS PARA ANÁLISE	37

5.1	<i>Effective Mode of Learning Cartonization: White-box Cartoon Representations</i>	37
5.2	<i>Generative Adversarial Networks for photo to Hayao Miyazaki style cartoons</i>	37
5.3	CartoonGAN: Generative Adversarial Networks for Photo Cartoonization	38
5.4	<i>CartoonLossGAN: Learning Surface and Coloring of Images for Cartoonization</i>	39
5.5	<i>Learning to Incorporate Texture Saliency Adaptive Attention to Image Cartoonization</i>	40
5.6	<i>Cartooniation Using White-box Technique in Machine Learning</i>	40
5.7	<i>PokéGAN: P2P (Pet to Pokémon) Styliz émon) Stylizer</i>	41
5.8	<i>Abstraction Perception Preserving Cartoon Face Synthesis</i>	42
5.9	<i>SDP-GAN: Saliency Detail Preservation Generative Adversarial Networks for High Perceptual Quality Style Transfer</i>	43
5.10	<i>Everyone Is a Cartoonist: Selfie Cartoonization With Attentive Adversarial Networks</i>	44
5.11	<i>Unpaired Cartoon Image Synthesis via Gated Cycle Mapping</i>	44
5.12	<i>GAN-Based Multi-Style Photo Cartoonization</i>	46
5.13	<i>Learning to Cartoonize Using White-box Cartoon Representations</i>	46
5.14	<i>AI-Enable Generating Human Faces using Deep Learning</i>	48
5.15	<i>Generating Cartoon Images from Face Photos with Cycle-Consistent Adversarial Networks</i>	48
5.16	<i>Analysis of Learning Mechanism of Generative Adversarial Network</i>	48
5.17	Métricas de avaliação	49
6	RESULTADOS	51
6.1	Q1 - De que forma as técnicas de transferência de estilo <i>cartoon</i> estão sendo usadas para produzir resultados com estilo consistente e expressivo na <i>NonPhotorealistic Rendering</i> (NPR)?	51
6.2	Q2 - Quais métricas foram utilizadas para avaliar a eficiência desses algoritmos/técnicas?	51
6.3	Q3 - Quais são os desafios e as limitações das técnicas de transferência de estilo <i>cartoon</i> na renderização não fotorrealística?	54
6.4	Discussão	56

7	CONCLUSÕES E TRABALHOS FUTUROS	58
	REFERÊNCIAS	59

1 INTRODUÇÃO

Considerada uma área com grande enfoque na pesquisa acadêmica devido à sua importância para computação gráfica, a renderização estilizada ou não fotorrealística, do inglês NonPhotorealistic Rendering (NPR), é uma técnica desenvolvida ao longo dos anos, que em contraste à síntese de imagens realista, propõe a geração de imagens e/ou de vídeos de cenas 3D em outros estilos diferentes do realismo do mundo real, como ilustrações, pinturas ou desenhos animados, que transmitem a ideia de arte feita à mão (FUN *et al.*, 2004). Estas imagens ou vídeos tendem a demonstrar traços que expressam emoções, com uma arbitrária interpretação visual flexível das características presentes na imagem ou no vídeo de entrada, de maneira oposta a propriedade do realismo, que entrega a definição total do objeto na cena (CARVALHO *et al.*, 2006) (Figura 1).

Figura 1 – Imagem Realista (à esquerda) versus Renderização Não Fotorrealística (NPR) (à direita)



Fonte: Wikipedia (2021).

Segundo Neto (2007), a utilização da NPR tem como vantagem em relação a renderização fotorrealística, “[...] a diminuição do tempo de renderização devido à redução da complexidade do processo de renderização, e a diminuição do espaço físico ocupado pelas imagens renderizadas devido a perda de informações da imagem causada pela NPR, p.13”. Também é ressaltado que os métodos de animações e o manuseio de especificações de modelos são mais compreensíveis.

As pesquisas na área de NPR procuram esclarecer os princípios e conceitos de vários métodos contendo diferenças no estilo e aparência visual, utilizados na concepção de peças de artes tradicionais (ilustração, pintura, desenho gráfico), visando na renderização expressiva e

estilizada, como interesse principal (KYPRIANIDIS, 2013).

Diante disto, pode destacar-se algumas áreas de aplicações da NPR: o *Cartoon*, utilizado tanto em filmes animados como em jogos que usam renderização em tempo real (Figura 2); o Desenho Técnico, que sintetiza as características da ilustração usadas em manuais técnicos, livros, objetivando evidenciar as informações geométricas mais relevantes (DANNER; WINKLHOFER, 2008) (Figura 3); a Visualização Científica, que aplicada à visualização de estruturas e dados retratados em ilustrações computadorizadas enfatizam exclusivamente detalhes importantes, como, por exemplo, a área de medicina, que faz uso desse método em diversas aplicações diferentes (FUN *et al.*, 2004) (Figura 4); e a Pinturas, que simula vários estilos com características artísticas (DANNER; WINKLHOFER, 2008) (Figura 5).

Este trabalho realiza uma revisão sistemática da literatura acerca das técnicas de renderização não fotorrealística que utilizam transferência de estilo com características do *Cartoon*, presentes na literatura. A pesquisa visa auxiliar pesquisadores e desenvolvedores de aplicações a compreender melhor essas abordagens e a identificar desafios para sua utilização.

O *Cartoon* é um estilo de desenho animado consumido tanto por crianças e adultos, sendo encontrado em todos os lugares nos meios de comunicação (jornais, revistas, desenhos) *online* ou impressos. O estilo *Cartoon* teve início nas histórias em quadrinhos, filmes de desenhos animados e faz parte das técnicas de renderização não fotorrealística. As principais características desse estilo são a cor sólida das regiões internas, e o contorno preto (DANNER; WINKLHOFER, 2008).

A estilização de imagens é composta por vários métodos que durante os anos passaram por melhorias projetadas no decorrer das pesquisas de autores com propósitos específicos dependendo do intuito da aplicação. Com isso, surgiram os métodos de transferência de estilo fundamentados no aprendizado através de redes neurais, que utilizam bases de dados para realização da estilização (CHEN *et al.*, 2018). A *Generative Adversarial Network* (GAN) é um desses métodos bem conhecido para transferência de estilo, visando a geração de novas amostras por meio de dados desconhecidos e conhecidos (ANDERSSON; ARVIDSSON, 2020). Sua tarefa é armazenar informações importantes da imagem de origem e decidir quais dessas informações podem ser transferidas para a imagem de destino (LI, 2021).


Ao analisar os diferentes métodos que utilizam transferência de estilo baseado em GAN, surge um questionamento relevante: quais são os principais desafios da aplicação das técnicas de renderização não fotorrealística com transferência de estilo *cartoon* em áreas como

Figura 2 – Um *cartoon* de um cientista louco estereotipado.




Fonte: Wikipédia (2022).

Figura 3 – Figura de um desenho técnico.



Fonte: IME Junior (2019).

Figura 4 – Gráfico de dispersão.



Fonte: Wikipedia (2021).

Figura 5 – Técnica de pintura artística.



Fonte: Zeng *et al.* (2009, p.2:8).

design, animação ou jogos?

Este trabalho está estruturado da seguinte forma. São apresentados os objetivos na Seção 1.1. A Seção 2 apresenta a fundamentação teórica que ajuda no entendimento dos conceitos relacionados aos problemas desta pesquisa. A Seção 3 aborda os trabalhos relacionados que ajudaram no desenvolvimento da pesquisa. A Seção 4 demonstra os passos metodológicos realizados na execução deste trabalho. A Seção 5 irá abordar os trabalhos que foram coletados a partir dos passos realizados na metodologia. A Seção 6 apresenta os resultados e a Seção 7 apresenta a conclusão.

1.1 Objetivos

1.1.1 *Objetivo geral*

Realizar uma revisão sistemática da literatura sobre técnicas de renderização não fotorrealística que utilizam transferência de estilo com características do *Cartoon*, a fim de identificar desafios na área e auxiliar pesquisadores futuros da área de NPR na criação de revisões bibliográficas de forma sistematizada e verificada de seus trabalhos.

1.1.2 *Objetivos específicos*

- Apresentar os conceitos fundamentais da transferência de estilo aplicada ao *Cartoon*.
- Realizar uma revisão sistemática da literatura para identificar os métodos mais relevantes e atuais de renderização não fotorrealística que utilizam transferência de estilo cartunesco, analisando suas principais características e resultados.
- Identificar, a partir dos estudos selecionados na revisão sistemática, as principais vantagens e desvantagens dessas técnicas, com base nas avaliações e resultados reportados pelos autores nos trabalhos analisados.

2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção, são apresentados conceitos fundamentais que irão ajudar na compreensão de alguns conceitos relacionados a NPR.

2.1 Renderização Não Fotorrealística

Os estudos de Renderização Não Fotorrealística (NPR) começaram a estimular o interesse da comunidade científica na década de 90. E por essa área ser ampla, objetivou-se na criação das mais variadas técnicas para renderização de imagens, que expressassem características diferentes conforme o propósito estabelecido da aplicação (GOOCH, 2003).

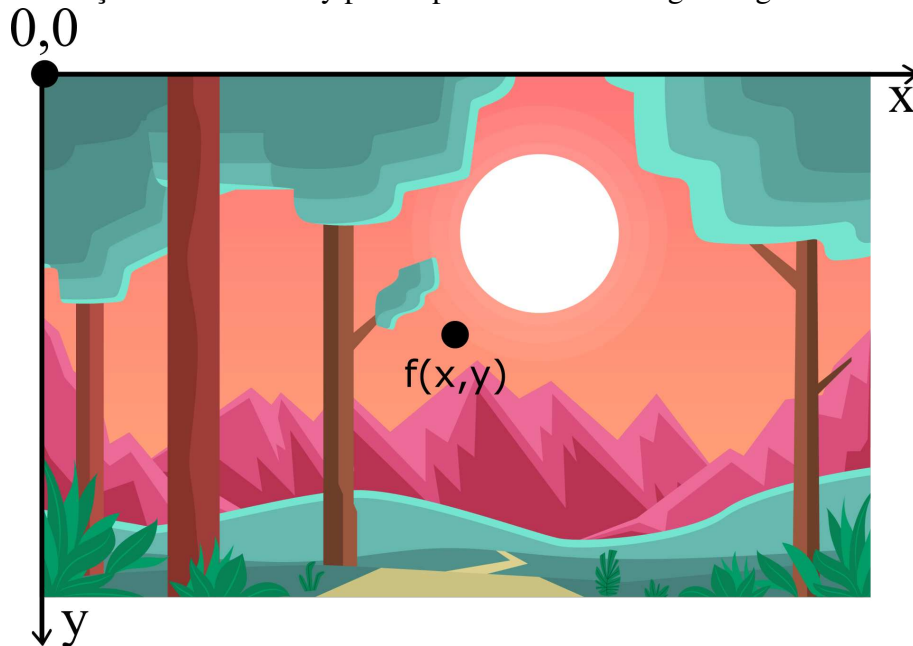
A NPR é uma área da computação gráfica composta por técnicas que têm em vista a renderização de imagens ou vídeos com características artísticas, com intuito de demonstrar traços que expressam emoções (CARVALHO *et al.*, 2006). Outra forma de definir a NPR seria a renderização de imagens que são oriundas de desenho, esboço, pintura, ilustração e animação. Tais características que transmitem a ideia de um trabalho manual presentes nessas imagens, entretanto elas são geradas através de algoritmos (BARILE *et al.*, 2008).

2.2 Imagem Digital

A construção de uma imagem é feita através de coordenadas x e y aplicadas a uma função bidimensional $f(x, y)$ (Figura 6), determinando a intensidade de cada *pixel* na imagem (APRENDIS, 2017). Essa imagem é representada por uma matriz, onde as coordenadas x e y equivalem aos índices das colunas e linhas respectivamente, e o valor de cada *pixel* armazenado na matriz representa a intensidade de brilho naquele ponto (GONZALEZ; WOODS, 2000). É importante destacar que o *pixel* é o menor elemento presente em uma imagem e portanto a resolução de uma imagem é determinada pela quantidade de pixels presentes nela, e quanto maior for a quantidade de pixels, melhor será a qualidade da imagem (EXPRESS, 2020).

O processamento de imagem digital usa uma imagem como entrada para gerar uma nova imagem com melhorias nas características da imagem original. Desse modo, há diversas técnicas de processamento de imagens que podem ser usadas em diversas aplicações, como métodos de filtragem, segmentação e reconhecimento na extração de informações importantes na imagem a ser tratada (APRENDIS, 2017). A seguir serão apresentados alguns conceitos básicos de processamento de imagens.

Figura 6 – Ilustração dos eixos x e y para representar uma imagem digital



Fonte: Elaborada pela Autora (2023).


2.3 Filtragem

O processamento de imagem, em sua fase inicial, começa pelo pré-processamento, onde são utilizados filtros para realçar detalhes, de maneira que a imagem obtida pelo processo tenha uma melhor qualidade em relação à original. Existem duas formas de categorizar os métodos de filtragem de imagem: técnicas de filtragem no domínio espacial, que trabalham exatamente sobre a matriz de *pixel*, e técnicas de filtragem no domínio da frequência, que fazem o uso da transformada de Fourier (“[...] ferramenta matemática obrigatória para a especificação e projeto de filtros no domínio da frequência”) (FILHO; NETO, 1999, p.99) da imagem.

As técnicas de filtragem no domínio espacial utilizam uma função g que resulta na imagem processada, a operação é dada por $g(x, y) = T [f(x, y)]$, de modo que $f(x, y)$ é a imagem real e T é um operador determinado de acordo com a vizinhança de (x, y) . É importante destacar que a vizinhança do *pixel* p possui um conjunto de 8 vizinhos distribuídos em dois conjuntos: o primeiro é composto por dois *pixels* na vertical e dois na horizontal Figura (7a), e o segundo é composto por quatro *pixels* dispostos nas diagonais (Figura 7b). Os conjuntos de coordenadas dos vizinhos são representados por $N4(p)$ e $Nd(p)$, respectivamente. A vizinhança composta pelos 8 *pixels* pode ser determinada pela união dos conjuntos $N4(p)$ e $Nd(p)$, e é representada por $N8(p)$ (Figura 7c) (FILHO; NETO, 1999). A operação de filtragem espacial de uma função $g(x, y)$ é feita por meio de uma matriz com dimensões $n \times n$, podendo ser utilizados filtros de:

passa baixa (filtram altas frequências para suavizar a imagem), passa alta (filtram as baixas frequências para destacar regiões e bordas de elevado contraste), e passa faixa (filtram uma região específica) (FILHO; NETO, 1999).

Figura 7 – a) 4-vizinhança; b) 4-diagonal; c) 8-vizinhança.



Fonte: (GONZALEZ; WOODS, 2000, p.26).


Albuquerque e Albuquerque (2000) apresentam resultados de dois desses filtros aplicados a uma imagem (Figura 8a) digital sem nenhuma modificação de acordo com uma matriz 3 x 3. A Figura 8b ilustra a aplicação de um filtro passa baixa com os valores iguais a 1, sendo perceptível que os contornos perdem um pouco da nitidez. Esse tipo de filtro é chamado de filtro médio, em razão de cada pixel da nova imagem gerada corresponder a média local da imagem original. A Figura 8c ilustra a aplicação de um filtro passa alta de detecção de bordas horizontais. A Figura 8d ilustra a aplicação de um filtro passa alta para realce de bordas horizontais e verticais.

2.4 Segmentação de imagem

A segmentação é uma etapa complexa por ser responsável por realizar a partição de uma imagem em diferentes regiões de *pixel* relevantes (ALBUQUERQUE; ALBUQUERQUE, 2000). A diferença entre as regiões é definida em áreas com nível de cor ou texturas parecidas, então a segmentação especifica um valor para cada *pixel* que determinará a qual região ele pertence (ALBUQUERQUE *et al.*, 2007). Falcão (2007) fala o porquê dessa etapa ser mais complicada, pois a principal razão se dá por causa da falta de informações sobre os objetos presentes na imagem.

A tarefa básica da segmentação é dividida em duas: 1) identificar a localização do objeto e 2) delinear a extração de área na imagem. Os métodos dessa etapa de extração são

Figura 8 – Matrizes para Filtragem de uma imagem. (a) - Imagem original. (b) - Imagem com filtro passa baixa. (c) - Imagem com Filtro passa alta. (d) - Imagem com Filtro passa alta com melhoramento de contraste



Fonte: Albuquerque e Albuquerque (2000, p.09).

baseados em regiões ou em bordas. Enquanto os métodos de bordas extraem contorno fechado, de modo que esse contorno é um caminho que separa a parte interna da externa do objeto, os métodos de regiões extraem o conjunto de *pixel* presente na parte interna do objeto. Algumas técnicas que fazem o uso de regiões são a limiarização, a classificação estatística e as redes neurais.


O método de limiarização por exemplo, objetiva gerar uma imagem nova a partir da escolha de um ponto t , conhecido como limiar. O processo acontece comparando cada pixel da imagem original com esse valor t , resultando assim, numa imagem com valores brancos e pretos (MOURA, 2018). Na Figura 9 é possível observar a aplicação de limiarização, em que cada Figura 9b, 9c, 9d, é apresentado um limiar diferente. Um problema na segmentação que utiliza limiar é o fato de ser difícil achar um t adequado, então para ajudar na resolução desse problema são aplicados métodos de redes neurais (ALBUQUERQUE *et al.*, 2007).

Após o processo de segmentação, vale ressaltar que as regiões detectadas são reconhecidas, isto é, rotuladas, passando por um classificador de objetos a partir das informações coletadas da imagem (ALBUQUERQUE; ALBUQUERQUE, 2000). O reconhecimento de objetos usando redes neurais faz o uso de redes treinadas para localizar os objetos separadamente, através das informações do pixel (EGMONT-PETERSEN *et al.*, 2002).

2.5 Transferência de estilo de imagens

Com a evolução dos métodos de NPR, a abordagem usando processamento de imagem e transferência de estilo baseada em aprendizado começou a ser apreciada por pesquisadores.

Figura 9 – Exemplo da aplicação de segmentação com limiarização usando diferentes valores de limiar para o tom de cinza




Fonte: Elaborada pela Autora (2022).

Gatys *et al.* (2015) descobriu que a concepção de uma imagem poderia ser realizada separando a representação de conteúdo e estilo das duas imagens de entrada através de *Convolutional Neural Networks* (CNN).

A transferência de estilo é uma técnica que faz o uso de duas imagens, na qual, é captado o estilo de uma e o conteúdo da outra, com a finalidade de combinar suas características na imagem final (Figura 10) (WANG; YU, 2020). Em vista disso, são usadas redes de aprendizado que objetivam na qualidade de estilização e otimizam o processo de compreensão, assim, é possível realizar a extração das informações mais importantes da imagem do mundo real, e os estilos a serem aplicados (DONG *et al.*, 2021).

A aplicação da transferência de estilo *cartoon* propõe-se a converter imagens ou vídeos com características visuais únicas, como bordas nítidas e sombreamento de cores suaves (GAO *et al.*, 2022), conservando assim o seu conteúdo semântico. Arruda *et al.* (2014) cita alguns atributos que definem o estilo *Cartoon*: o desenho deve ser delimitado por contorno preto e as regiões de cores iguais com nível de saturação elevado; a imagem ou cena não podem apresentar imperfeições, ou partes faltantes; deve-se manter o conteúdo semântico da original na imagem renderizada; o aspecto visual da imagem renderizada deve ser agradável. Wang e Yu (2020) mencionam que a transferência de estilos entre imagens não é um trabalho fácil, com isso

Figura 10 – A imagem (c) foi gerada a partir da combinação do conteúdo da imagem (a) e do estilo da imagem (b).



Fonte: adaptado do Andersson (2020, n.p).

pesquisadores estudam maneiras de realizar esse processo de tradução mais simples por meio das redes de aprendizado profundo (GAO *et al.*, 2022).

2.6 Redes Adversárias Generativas

As redes neurais são ferramentas muito utilizadas na área de inteligência artificial. Elas são um modelo computacional fundamentado no funcionamento do cérebro humano e objetivam absorver conhecimento através de treinamento e então utilizá-lo em alguma aplicação para uma finalidade específica.

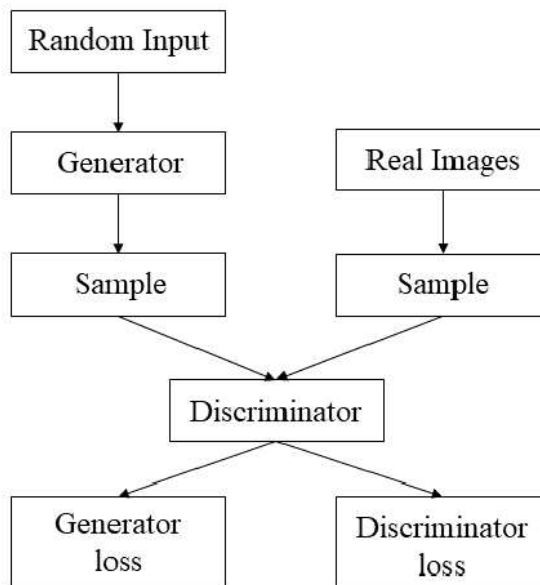
A Rede Adversária Generativa (GAN) é um método utilizado para a otimização de modelos generativos baseados em aprendizado profundo, sendo assim, uma abordagem promissora, utilizada pelos pesquisadores, por exemplo, na transferência do estilo entre imagens. Ela é responsável por gerar imagens por meio de duas redes neurais que são treinadas de formas diferentes (DONG *et al.*, 2021). Essas duas redes são chamadas de geradoras e discriminadoras. A rede geradora produz o conteúdo, fazendo uso de uma função de mapeamento $G: P \rightarrow C$, responsável por traduzir de forma instantânea uma imagem p realista em uma imagem c com características artísticas, por exemplo, de desenho animado (DONG *et al.*, 2021). A imagem p é dada por um conjunto de dados de treinamento $S_{data}(p) = \{p_i \mid i = 1 \dots N\} \subset P$, onde o N representa a quantidade de imagens reais e o c é dado pelo conjunto de dados de treinamento de imagens estilizadas $S_{data}(c) = \{c_i \mid i = 1 \dots M\} \subset C$, em que o M representa a quantidade de imagens treinadas (CHEN *et al.*, 2018). O discriminador é uma rede responsável por avaliar se um determinado conteúdo é real ou desenvolvido pelo gerador. Ele utiliza uma função discriminadora D treinada para diferenciar se a imagem de entrada é real ou gerada pelo gerador com função de mapeamento G (DONG *et al.*, 2021). Essa função de perda $L(G, D)$ indicará o

valor de proximidade de quão perto a imagem de saída é parecida com estilo de desenho animado. Ela é dividida em duas partes: $L_{adv}(G, D)$ (perda adversária), que atua na rede geradora e $L_{con}(G, D)$ (perda de conteúdo), responsável por manter o conteúdo da imagem no processo de estilização. O ω é um parâmetro para equilibrar as duas perdas geradas, pois quanto maior o valor de ω , mais informações de conteúdo são captadas (CHEN *et al.*, 2018). Função de perda:

$$L(G, D) = L_{adv}(G, D) + \omega L_{con}(G, D) \quad (2.1)$$

A Figura 11 demonstra um exemplo de arquitetura GAN usada por Thakur *et al.* (2021) no seu trabalho, utilizando rede geradora e discriminadora.

Figura 11 – Exemplo de uma arquitetura GAN.



Fonte: Thakur *et al.* (2021, p.295).

3 TRABALHOS RELACIONADOS

A seguir, são apresentados alguns estudos relacionados ao presente trabalho, que consistem em *Surveys: Image-to-Image Translation; Applications of Generative Adversarial Networks; Neural Style Transfer*; e *Cartoon Image Processing*. Esses estudos são relevantes para esta pesquisa por abordarem tópicos do processamento de imagens e técnicas de geração de conteúdo visual.

3.1 *Image-to-image translation: Methods and applications*

Pang *et al.* (2021) apresentam uma revisão sistemática de técnicas de tradução de imagem para imagem que foram publicadas no período de 2016 a 2021. Essas técnicas permitem a tradução de imagem criando uma imagem final que combina o conteúdo da imagem original com o estilo desejado, proporcionando resultados estéticos e visuais (Figura 12), por meio de modelos generativos. Diante disto, o estudo começa com uma análise desses métodos de tradução, onde são explicados conceitos e são discutidas as abordagens de processamento de imagem baseadas em aprendizado supervisionado ou não, como redes de transferência de estilo usando GANs ou *variational autoencoders* (codificadores automáticos variacionais). O autor ainda revisa várias aplicações práticas da tradução, como a tradução de imagens de um domínio para outro, a conversão de imagens de baixa resolução para alta resolução, a manutenção de elementos em imagens, a remoção de ruído, e a estilização de imagens em diferentes estilos artísticos. Por fim, o estudo discute os desafios enfrentados pelos métodos de tradução de imagem para imagem, como a preservação de características importantes na imagem de origem e a generalização para diferentes domínios de imagem.

3.2 *Applications of Generative Adversarial Networks (GANs): An Updated Review*

Alqahtani *et al.* (2021) propõem uma revisão das aplicações de GANs, onde eles abordam as técnicas de aprendizado que permitem a geração de dados sintéticos realistas, tentando identificar as vantagens, desvantagens e desafios significativos das GANs. Esse estudo destaca as principais aplicações de GANs em áreas como geração de imagens, tradução de estilo, geração de texto ou música para imagem, entre outras. Os autores mencionam que o uso de GANs não se limita apenas à obtenção de resultados estéticos e visuais em imagens e vídeos. Essa tecnologia também é aplicada na detecção de células cancerígenas e na avaliação da eficácia

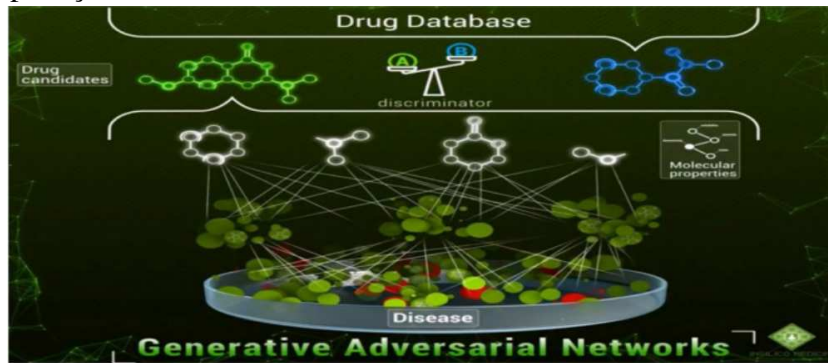
de medicamentos para tratar doenças. (Figura 13). Para cada trabalho incluído em seu estudo, foram apresentados os principais desafios enfrentados pelos métodos baseados em GANs, bem como as técnicas e arquiteturas utilizadas para resolução. Além disso, o artigo discute os avanços recentes na área de GANs, incluindo o uso de redes neurais recorrentes e o treinamento de modelos. Por fim, o estudo destaca as principais limitações e desafios futuros para a aplicação de GANs em diversas áreas, bem como as oportunidades de pesquisa em aberto.

Figura 12 – Exemplo de tradução de imagem para imagem

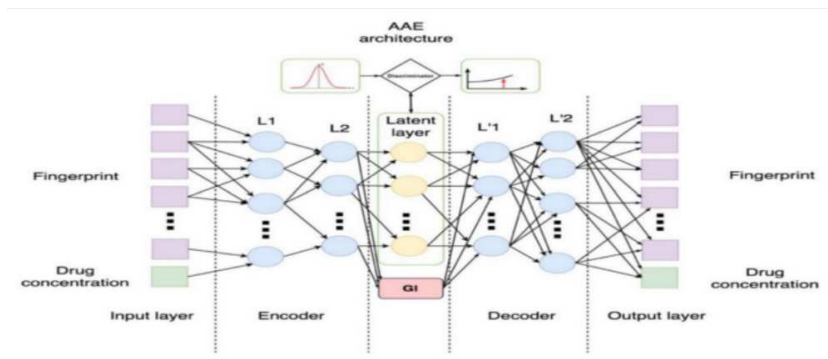


Fonte: Pang *et al.* (2021, p.3859).

Figura 13 – Aplicação de GANs na área da saúde



Aplicação de GAN na descoberta de drogas




Aplicação de GAN em oncologia

Fonte: Alqahtani *et al.* (2021, p.545).

3.3 *Neural Style Transfer: A Critical Review*

Singh *et al.* (2021) realizaram uma revisão sistemática crítica sobre as técnicas de processamento de imagens que utilizam redes neurais para aplicar o estilo de uma imagem em outra (Figura 14). Os autores fizeram uma divisão de temas se concentrando no desenvolvimento das GANs e assim resumindo os avanços conduzidos até o ano de 2021. Deste modo, são descritas as diferentes abordagens para a transferência de estilo neural. A revisão apresenta uma comparação crítica entre a transferência de estilo com aprendizado profundo e outras técnicas de processamento de imagens. Também são discutidas as limitações dos métodos. Por fim, o artigo expõe possíveis caminhos para futuras pesquisas na área, incluindo o desenvolvimento de técnicas mais eficientes que poderiam ser usadas em vídeos não iterativos ou realidade aumentada.

Figura 14 – Exemplo de tradução de imagem para imagem




Fonte: Singh *et al.* (2021, p.131602).

3.4 *Cartoon Image Processing: A Survey*

Zhao *et al.* (2022) apresentam em seu estudo uma revisão da literatura sobre o processamento de imagens do *cartoon* 2D, conhecida como CIP (*Cartoon Image Processing*). Esse estudo aborda a aplicação do estilo visual característico de desenhos animados a qualquer imagem (Figura 15). O trabalho é organizado começando por uma explicação geral sobre o tema, abordando as principais técnicas de processamento de imagens catalogadas e por fim trazendo

as aplicações e conclusões. Os autores descrevem as diferentes técnicas de processamento desenvolvidas até o ano de 2021, sendo elas: a remoção de ruído, a segmentação, a avaliação de qualidade, a transferência de estilo, a colorização, a detecção, a geração, e a edição. Todas essas abordagens envolvem a preocupação com a suavização e a aplicação de estilos diferentes, melhorando assim a qualidade das imagens geradas. E o foco deste trabalho é na análise das semelhanças e diferenças dos métodos de processamento de imagem baseados em aprendizado profundo de acordo com diferentes cenários e aplicações.

Figura 15 – Resultados de transferência de estilo de desenho animado



Fonte: Zhao *et al.* (2022, p.2737).

3.5 O presente trabalho

No Quadro 1, são apresentados os trabalhos relacionados e o proposto, destacando suas semelhanças e diferenças. Pode-se observar que todos os trabalhos realizam revisões sistemáticas da literatura, entretanto apenas dois trabalhos realizam essa revisão sistemática utilizando como foco a transferência de estilo cartoon: o trabalho de Zhao *et al.* (2022) e este trabalho proposto.

O presente trabalho oferece uma análise do estado da arte e os passos necessários para a catalogação dos artigos em comparação com a pesquisa de Zhao *et al.* (2022), fornecendo um guia para outros pesquisadores seguirem. Apesar de serem pesquisas recentes, algumas informações estão desatualizadas, uma vez que, no ano de 2022, foram lançadas novas técnicas que não foram contempladas em seus trabalhos. Os passos para a realização dessa análise

Quadro 1 – Comparativo dos trabalhos relacionados e o proposto.

Trabalhos	Revisão sistemática da literatura	A revisão foi feita para a transferência de estilo cartoon?
Pang <i>et al.</i> (2021)	x	
Alqahtani <i>et al.</i> (2021)	x	
Singh <i>et al.</i> (2021)	x	
Zhao <i>et al.</i> (2022)	x	x
Trabalho proposto	x	x

Fonte: Elaborado pela Autora (2023).

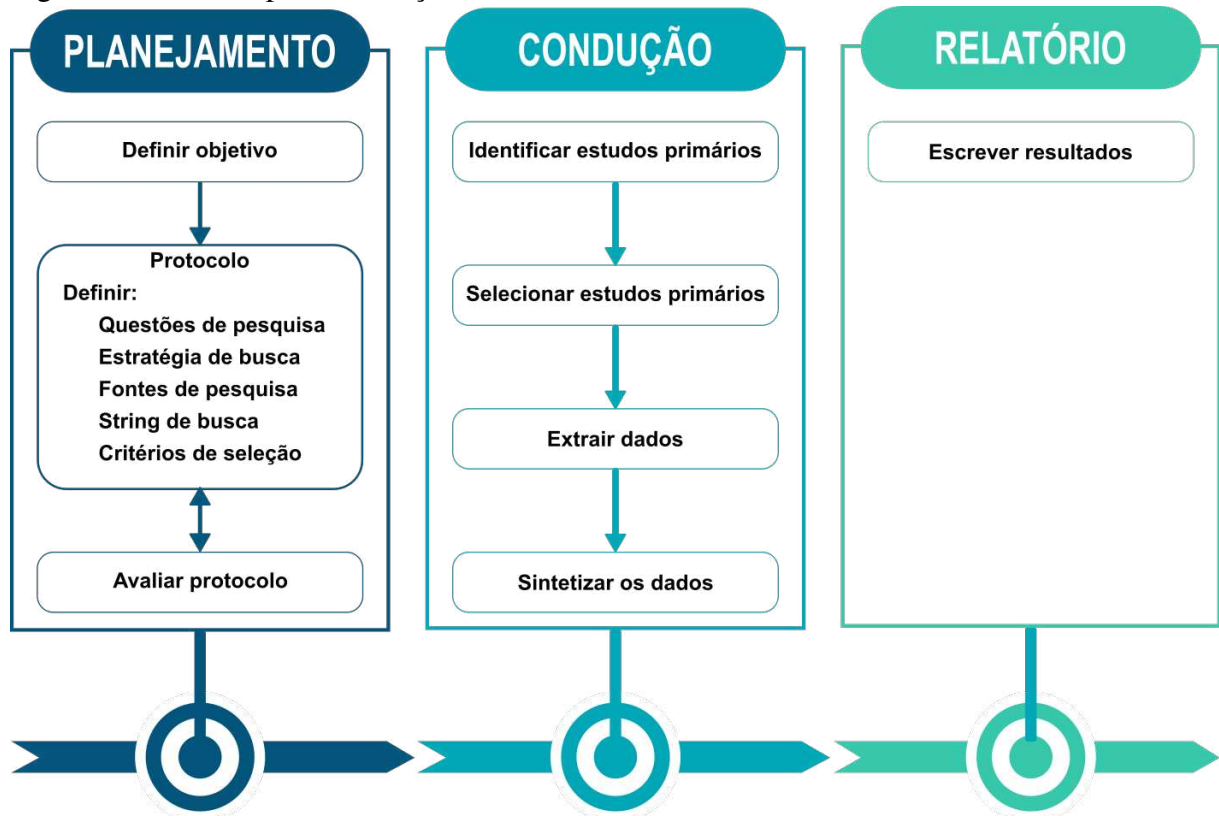
incluem a revisão sistemática da literatura com a seleção de artigos relevantes, a análise dos trabalhos selecionados e a identificação de desafios. Além disso, a análise pode contribuir para futuras pesquisas e desenvolvimento de aplicações. Portanto, afirmar que este trabalho oferece uma análise atualizada do estado da arte pode destacar a importância e a relevância do trabalho.

4 METODOLOGIA

Esta pesquisa consiste em realizar uma Revisão Sistemática da literatura, a fim de identificar os estudos publicados sobre a temática dos métodos atuais de renderização não fotorrealística que utilizam transferência de estilo com características do *cartoon*.

A Revisão Sistemática da Literatura visa reduzir erros sistemáticos e casuais ao estabelecer com precisão o procedimento a ser seguido. Esse procedimento inclui alguns passos como: a definição de uma estratégia de busca que permite a integridade da pesquisa, de tal forma que possa ser avaliada por outros pesquisadores; a especificação de um período de busca se necessário; a busca pelos trabalhos que correspondam a palavras-chave predefinidas; e a definição clara dos critérios de inclusão e exclusão dos trabalhos encontrados. Neste capítulo, são detalhadas as ações executadas durante a elaboração e execução da revisão. Diante disto, a Figura 16, apresenta as etapas da revisão sistemática seguida por este trabalho, utilizando as orientações de (KITCHENHAM *et al.*, 2007 apud DERMEVAL *et al.*, 2020, p. 05) como referência para planejar, conduzir e escrever os resultados.

Figura 16 – Passos para realização de uma revisão sistemática da literatura



Fonte: Elaborada pela autora, adaptada de Dermeval *et al.* (2020).

4.1 Planejamento

Nesta seção são descritos as etapas do planejamento da revisão conduzidas durante a realização deste estudo. O objetivo do planejamento é estabelecer um conjunto de etapas fundamentais para a revisão, onde serão detalhados os métodos utilizados nesta pesquisa, garantindo a confiabilidade dos resultados obtidos.

4.1.1 *Objetivo e identificação de uma necessidade de revisão*

O propósito da revisão sistemática da literatura realizada neste trabalho é investigar as técnicas de renderização não fotorrealística que utilizam transferência de estilo e possuem características do *cartoon*, que foram publicadas no período entre 2018 a 2023, a fim de identificar seus desafios.

Na busca por revisões sistemáticas desse tema, é notória a escassez de trabalhos que apresentem o estado da arte sobre o tema proposto. Embora o trabalho do Zhao *et al.* (2022), referenciado nos trabalhos relacionados, aborde processamento de imagem *cartoon*, ele abrange técnicas mais amplas, como colorização, detecção em imagens *cartoon*, enquanto este trabalho é mais específico ao identificar os desafios das técnicas de NPR com transferência de estilo *cartoon* que utilizam aprendizado profundo das GANs. Além disso, este trabalho incorpora técnicas publicadas em 2022 e 2023 que não foram contempladas pelo trabalho do Zhao *et al.* (2022). No fim, essas técnicas são relevantes para diversas áreas, como animação, jogos ou design.

4.1.2 *Definindo o protocolo*

Nesta seção são descritos os procedimentos de definição de questões de pesquisa, a estratégia de busca, a *string* de busca e os critérios para inclusão ou exclusão.

4.1.2.1 *Questões de pesquisa*

A finalidade deste tópico é ajudar no processo de busca e obtenção dos dados sobre os desafios e aplicações das técnicas de renderização não fotorrealística com transferência de estilo do *cartoon*. No Quadro 2 foram estabelecidas 3 questões formuladas para auxiliar na compreensão e exploração desse tema. Dentre os motivos que levaram à escolha dessas questões, destacam-se o interesse em explorar o potencial dessas técnicas para produzir renderizações com estilo consistente e expressivo, bem como, a identificação das métricas mais utilizadas

por esses autores para avaliar e comparar a qualidade de suas renderizações, de modo geral, a determinação dos desafios e das limitações enfrentados nesse contexto.

Quadro 2 – Questões de pesquisas

Código	Pergunta
Q1	De que forma as técnicas de transferência de estilo <i>cartoon</i> estão sendo usadas para produzir resultados com estilo consistente e expressivo na NPR?
Q2	Quais métricas são utilizadas para avaliar a eficiência desses algoritmos/técnicas?
Q3	Quais são os desafios e as limitações das técnicas de transferência de estilo <i>cartoon</i> na NPR?

Fonte: Elaborado pela Autora (2023).

4.1.2.2 Estratégia de busca dos estudos

Devido ao grande número de etapas e atividades envolvidas na realização de uma revisão sistemática, o processo torna-se uma tarefa trabalhosa e repetitiva. Portanto, é essencial contar com o suporte de uma ferramenta computacional para melhorar a qualidade do processo. Diante disto, a revisão sistemática foi realizada com o suporte da ferramenta *Parsifal*. Essa ferramenta possui as vantagens de ser utilizada de forma *online* e de permitir a colaboração entre pesquisadores. O repositório *Google Acadêmico* foi escolhido devido à sua ampla coleção de informações, incluindo artigos de diversas fontes, tais como *SCieLO*, *Elsevier* e *IEEE*, dentre outras.

4.1.2.3 Elaboração da String de Busca

Para incluir apenas os trabalhos que preenchessem os critérios de elegibilidade estabelecidos na seção seguinte, foi elaborada uma *string* de busca a partir das palavras-chave extraídos do objetivo e das questões de pesquisa: ("*techniques*" or "*method*") and ("*style transfer*") and ("*Generative adversarial networks*") and ("*cartoon*").

4.1.2.4 Critérios de inclusão e exclusão

Com o objetivo de obter estudos de boa qualidade para avaliação e reduzir viés do pesquisador na fase de seleção, são estabelecidos dois conjuntos de critérios distintos: critérios de inclusão identificados por CI (Quadro 3) e critérios de exclusão identificados por CE (Quadro 4). Na pesquisa científica, existe três tipos de artigos: primário, secundário, e terciário. O

primário descreve resultados originais de uma pesquisa realizada pelos próprios autores, a pesquisa secundária se baseia em fontes primárias para consolidar informações de diferentes pesquisas, enquanto o terciário agrega informações de diversas fontes primárias e secundárias para fornecer uma abordagem mais abrangente sobre um tema específico (KITCHENHAM *et al.*, 2007 apud DERMEVAL *et al.*, 2020, p. 05). E como este trabalho é uma revisão sistemática da Literatura, ele se enquadra em um estudo secundário, por isso, são avaliados artigos primários.

Quadro 3 – Critérios de Inclusão (CI)

Critério	Descrição
CI.1	Artigos primários.
CI.2	Artigos que cite técnicas de transferência de estilo <i>cartoon</i> não fotorrealísticas.
CI.3	Artigos que respondam a alguma pergunta de pesquisa.
CI.4	Artigos que estejam escritos em inglês ou em português.
CI.5	Artigos que tenham sido publicados no período de 2018 a 2023.

Fonte: Elaborado pela Autora (2023).

Quadro 4 – Critérios de Exclusão (CE)

Critério	Descrição
CE.1	Artigos que não contêm as palavras-chave.
CE.2	Artigos que não respondem a pelo menos uma das questões.
CE.3	Artigos duplicados.
CE.4	Artigos que não se encontram disponíveis.

Fonte: Elaborado pela Autora (2023).

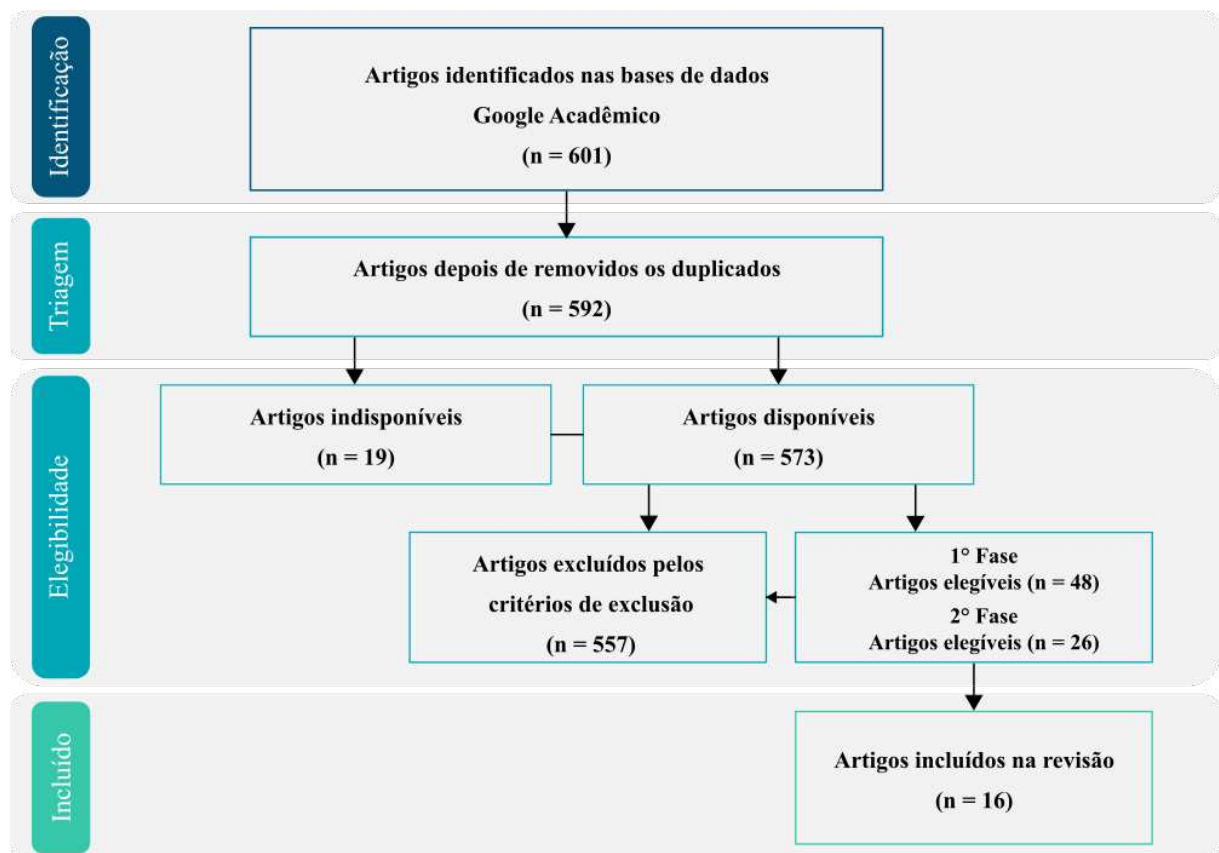
4.1.2.5 Avaliação do protocolo

O protocolo proposto foi avaliado ao verificar a presença de 5 trabalhos básicos e importantes na área de NPR: Andersson e Arvidsson (2020), Li *et al.* (2020), Chen *et al.* (2018), Dong *et al.* (2021) e Shu *et al.* (2021), os quais foram utilizados como forma de controle. Inicialmente, a string de busca selecionada foi ("*non-photorealistic rendering*") and ("*methods*") and ("*style transfer*") and ("*cartoon*"). No entanto, devido à sua abrangência restrita, apenas 112 artigos foram retornados, resultando na exclusão do trabalho de Andersson e Arvidsson (2020) e no risco de não selecionar outros estudos relevantes. Como solução, a *string* foi reformulada para ("*techniques*" or "*method*") and ("*style transfer*") and ("*Generative adversarial networks*") and ("*cartoon*"), abrangendo assim um número maior de trabalhos, resultando em um total de 601 artigos. Então, esta segunda *string* de busca adaptada foi considerada adequada somente após a identificação desses cinco estudos dentre todos os trabalhos recuperados da base bibliográfica.

4.2 Condução

Nesta seção, é abordada a fase de condução da revisão, que consistiu na implementação do protocolo. A Figura 17 apresenta todas as atividades executadas. Na atividade de identificação dos estudos, é possível visualizar o quantitativo de artigos disponíveis acerca da temática na base de dados do *Google Acadêmico* até o dia 31 de maio de 2023. Durante a atividade de triagem, ocorreu a primeira eliminação de 9 artigos duplicados com o auxílio da ferramenta *Parsifal*, segundo o CE.3. A atividade de elegibilidade foi dividida em duas fases (aplicando os critérios CI.1, CI.4, CE.1, CE.4): a primeira fase foi feita a partir da análise dos estudos por meio do título e resumo, resultando na eliminação de 525 artigos que estavam fora do escopo da pesquisa; na segunda fase, foi realizada uma análise dos estudos através das seções de resultados e conclusões dos artigos, resultando na exclusão de 22 artigos, totalizando 557 artigos excluídos. Por fim, na atividade incluídos, os critérios CI.3 e CE.2 foram aplicados, excluindo 10 artigos, a partir da leitura completa do documento, totalizando 16 artigos a serem revisados.

Figura 17 – Fluxograma do processo de seleção dos artigos disponíveis na base de dados *Google acadêmico*



Fonte: Elaborada pela autora

A extração de dados é apresentada no Capítulo 5 com informações coletadas de cada

artigo realizada durante a leitura completa, que visou na identificação do objetivo, das vantagens, das desvantagens mencionadas pelo autor, das métricas utilizadas para avaliar a eficiência e qualidade das técnicas. A síntese dos dados é abordada na seção de resultados.


5 ESTUDOS SELECIONADOS PARA ANÁLISE

Nesta seção, serão apresentados os trabalhos selecionados nesta revisão, com o intuito de resumir suas principais características, vantagens e desvantagens, bem como as métricas utilizadas pelos autores para avaliar suas abordagens.

5.1 *Effective Mode of Learning Cartoonization: White-box Cartoon Representations*

No trabalho de Anand (2022), foi proposta uma abordagem eficiente e eficaz para a cartoonização de imagens, cujo objetivo era identificar três representações fundamentais: a representação de superfície, a representação de estrutura e a representação de textura. Como resultado dessa abordagem, foram obtidos resultados altamente significativos e satisfatórios em termos de fidelidade e estilização das imagens, quando comparados a outras abordagens existentes. Uma das principais vantagens desse método é a sua flexibilidade e capacidade de ser controlado pelo usuário, permitindo ajustes e personalizações conforme necessário. Além disso, os resultados obtidos foram consistentemente notáveis e de alta qualidade, demonstrando a efetividade da técnica (Figura 18).

Figura 18 – Imagem de entrada à esquerda, resultado da técnica à direita



Fonte: Anand (2022, p.233).

5.2 *Generative Adversarial Networks for photo to Hayao Miyazaki style cartoons*

No trabalho de Andersson e Arvidsson (2020) apresentaram uma técnica de transferência de estilo, que possibilita a conversão de imagens fotográficas para o estilo de *cartoon* inspirado por *Miyazaki*. A abordagem baseada em GANs mostrou-se promissora, gerando imagens com características estilísticas bastante similares ao estilo de animação característico

de *Miyazaki* (Figura 19). Além disso, em alguns casos, a técnica alcançou um desempenho superior em comparação com outras técnicas já existentes. Dentre as vantagens do método, destaca-se a facilidade com que ele produz características faciais de desenhos animados, como olhos expressivos, bocas e cabelos estilizados. Porém, vale ressaltar que a técnica também apresenta algumas desvantagens. Uma delas é a necessidade de um grande conjunto de dados para treinar a rede GAN. Esse requisito pode dificultar a aplicação da abordagem em cenários com restrições de dados. Além disso, os resultados estéticos obtidos, embora sejam bastante satisfatórios em muitos casos, ficaram abaixo do esperado em comparação com outros modelos avaliados pelos autores.

Figura 19 – Imagem de entrada à esquerda, resultado da técnica à direita



Fonte: Andersson e Arvidsson (2020, n.p).

5.3 *CartoonGAN*: Generative Adversarial Networks for Photo Cartoonization

No trabalho de Chen *et al.* (2018) apresentaram uma proposta que se baseia no uso de GANs para transformar imagens fotográficas em estilo *cartoon*. Para alcançar esse resultado, foram utilizados conjuntos de imagens fotográficas e de desenhos animados durante o processo de treinamento. Os resultados obtidos foram bastante promissores, demonstrando a notável capacidade do *CartoonGAN* em gerar imagens no estilo *cartoon* com alta qualidade e fidelidade preservada em relação às imagens originais. Essa abordagem conseguiu manter a essência e o conteúdo original das fotos de entrada, o que é de extrema importância ao realizar tais transformações. Uma das principais vantagens do *CartoonGAN* em relação a outros métodos

existentes é sua eficiência no processo de treinamento. Isso significa que o modelo alcança bons resultados em um menor período de tempo, tornando o processo mais rápido e viável para diversas aplicações práticas (Figura 20). Além disso, o *CartoonGAN* destaca-se por preservar as bordas nítidas e o sombreamento suave nas imagens geradas, o que contribui para a qualidade visual do resultado final. Essa característica é especialmente relevante ao se considerar a estética e a aparência do estilo *cartoon*.

Figura 20 – Imagem de entrada à esquerda, resultado da técnica à direita



Fonte: Chen *et al.* (2018, p.9471).

5.4 *CartoonLossGAN: Learning Surface and Coloring of Images for Cartoonization*

No trabalho de Dong *et al.* (2021), propuseram uma abordagem baseada em GANs para a conversão de imagens em estilo *cartoon*, cujo objetivo é aprender a representação de superfície e a coloração das imagens para produzir *cartoons*. Os resultados obtidos sugerem que essa abordagem é capaz de gerar *cartoons* de alta qualidade, preservando o conteúdo das imagens originais, e também supera outras abordagens existentes em termos de métricas de avaliação (Figura 21). Uma das vantagens significativas dessa estratégia é que ela torna o treinamento do modelo mais fácil e estável, o que pode contribuir para uma maior eficiência e aplicabilidade em diversos contextos. Entretanto, é importante mencionar que os autores reconhecem algumas limitações em sua abordagem. Em particular, eles identificam que sua técnica tem dificuldade de gerar caricaturas faciais com precisão.

5.5 *Learning to Incorporate Texture Saliency Adaptive Attention to Image Cartoonization*

No trabalho de Gao *et al.* (2022) introduziram um modelo GAN voltado para a cartoonização de imagens, com o objetivo de produzir efeitos de *cartoon* mais vívidos. Os resultados obtidos demonstraram uma melhoria significativa na preservação dos detalhes, cores e texturas das imagens originais, além da criação de resultados visualmente agradáveis (Figura 22). Uma das principais vantagens desse modelo é a sua facilidade de treinamento. A abordagem desenvolvida pelos autores permite que o GAN seja treinada de forma mais eficiente e com menos complexidade, tornando o processo acessível mesmo para usuários com menos experiência em técnicas de aprendizado de máquina.

Figura 21 – Imagem de entrada à esquerda, resultado da técnica à direita



Fonte: Dong *et al.* (2021, p.495).

5.6 *Cartooniation Using White-box Technique in Machine Learning*

O trabalho de Harshitha *et al.* (2020) resultou em uma solução para a transformação de fotos de cenas do mundo real em imagens de estilo *cartoon*. O objetivo principal era identificar separadamente a representação de superfície, a representação de estrutura e a representação de textura nas imagens processadas. Os resultados obtidos com a abordagem desenvolvida por eles mostraram-se claramente superiores em comparação com outros métodos utilizados para a mesma finalidade (Figura 23). Essa abordagem tem como vantagens a capacidade de produzir imagens e vídeos cartoonizados de alta qualidade, o que torna possível aplicar essa técnica em diversas áreas, como entretenimento, publicidade e arte digital.

Figura 22 – Imagem de entrada à esquerda, resultado da técnica à direita



Fonte: Gao *et al.* (2022, p.6).

Figura 23 – Imagem de entrada à esquerda, resultado da técnica à direita



Fonte: Harshitha *et al.* (2020, n.p).

5.7 *PokéGAN: P2P (Pet to Pokémon) Styliz émon) Stylizer*

No trabalho de Hedge *et al.* (2021), propuseram uma abordagem para transformar imagens de animais em ilustrações com características de estilo semelhantes aos desenhos utilizados na série Pokémon. Um dos resultados promissores obtidos nessa pesquisa foi a identificação de truques inteligentes empregados por algumas das redes geradoras dentro da rede modificada do *cartoon-GAN*. Em determinadas iterações, essas redes aprenderam a criar um artefato visualmente agradável que se assemelha a uma pokébola. Dentre as vantagens dessa abordagem,

destacou-se a criação manual de máscaras de segmentação. Essas máscaras permitiram um significativo aprimoramento no desempenho da segmentação em imagens complexas, resultando em maior precisão nos resultados (Figura 24). No entanto, apesar dos avanços alcançados, a transferência de estilo apresentou algumas desvantagens. Um dos problemas identificados foi a variação significativa nos resultados, dependendo das características da imagem de entrada, como a presença de cores brilhantes e saturadas, o que resultou em artefatos indesejados ou pouco estilo transferido. Além disso, observou-se que certos tipos de animais podem ter menos sucesso na transferência de estilo do que outros.

Figura 24 – Imagem de entrada à esquerda, resultado da técnica à direita



Fonte: Hedge *et al.* (2021, p.17).

5.8 *Abstraction Perception Preserving Cartoon Face Synthesis*

No trabalho de Ho *et al.* (2023), propuseram uma abordagem para a síntese de faces no estilo *cartoon* com o intuito de preservar a percepção do rosto original, mantendo a abstração característica dos desenhos animados. Como resultado, o método conseguiu preservar tanto a percepção da face original quanto as características abstratas do *cartoon*. Uma das principais vantagens dessa abordagem é a melhor preservação dos traços visuais do rosto em comparação a outros métodos de síntese de rostos em estilo *cartoon* (Figura 25). Entretanto, vale destacar que essa técnica não é isenta de desvantagens. Os autores identificaram que, em alguns casos, o método proposto pode gerar ruídos nas imagens resultantes e produzir rugas inesperadas nos rostos dos personagens. Portanto, embora seja uma abordagem promissora para a síntese de

faces em estilo *cartoon*, é importante estar ciente das possíveis imperfeições que podem surgir.

Figura 25 – Imagem de entrada à esquerda, resultado da técnica à direita



Fonte: Ho *et al.* (2023, n.p).


5.9 *SDP-GAN: Saliency Detail Preservation Generative Adversarial Networks for High Perceptual Quality Style Transfer*

No trabalho de Li *et al.* (2020) propuseram um método baseado em GAN, denominado SDP-GAN, com o objetivo de preservar informações detalhadas de saliência ao realizar a tradução de imagens não pareadas do domínio de origem para o domínio de destino. O ponto forte desse método é a capacidade de traduzir imagens com ou sem objetos salientes, ao mesmo tempo em que se concentra em preservar os detalhes das regiões de destaque, utilizando o mapa de saliência fornecido como guia. Uma das principais vantagens do SDP-GAN é a função de perda de conteúdo da imagem, projetada para garantir que as imagens geradas mantenham seu conteúdo semântico original. Dessa forma, as características principais da imagem de entrada são preservadas na imagem de saída, o que resulta em traduções de alta qualidade (Figura 26). Porém, o método apresenta algumas desvantagens importantes. Primeiramente, ele não permite o controle dos resultados da detecção de saliência, o que pode ser limitante em certos cenários. Além disso, o SDP-GAN não é adequado para tarefas em que os objetos de saliência são alterados significativamente, o que pode prejudicar o desempenho em certas aplicações específicas.

5.10 *Everyone Is a Cartoonist: Selfie Cartoonization With Attentive Adversarial Networks*

No trabalho de Li *et al.* (2019), propuseram uma abordagem baseada em GANs para a cartoonização de selfies. Os resultados principais indicaram que o método foi bem-sucedido na transformação das selfies em desenhos animados, preservando tanto a estrutura geral quanto as características faciais detalhadas. Uma das vantagens da abordagem é o uso de uma rede neural atenta, que se concentra nas regiões faciais da imagem de entrada, gerando resultados mais precisos (Figura 27). Por outro lado, o método apresenta algumas desvantagens. Notou-se que as mudanças de gradiente não são óbvias na maioria das regiões, exceto nas partes de borda das estruturas faciais. Isso pode resultar em algumas limitações na transformação de certas áreas da imagem, podendo afetar a fidelidade do desenho gerado em algumas situações.

Figura 26 – Imagem de entrada à esquerda, resultado da técnica à direita



Fonte: Li *et al.* (2020, p.374).

5.11 *Unpaired Cartoon Image Synthesis via Gated Cycle Mapping*

No trabalho de Men *et al.* (2022), propuseram um método de síntese de imagens de *cartoon* não pareado que permite a transferência adaptativa de geometria para fotos diversas. Os resultados obtidos demonstraram a eficácia e superioridade desse método. Uma das principais vantagens desse método é que ele fornece controles flexíveis para estilos de desenho animado

Figura 27 – Imagem de entrada à esquerda, resultado da técnica à direita



Fonte: Li *et al.* (2019, p.657).

desejados, o que possibilita ao usuário obter resultados personalizados. Além disso, o método consegue preservar as estruturas de conteúdo das imagens, o que é essencial para garantir que os elementos importantes não sejam perdidos durante a síntese. Outra vantagem é que esse método também pode ser aplicado a vídeos, ampliando suas possibilidades de uso (Figura 28). Entretanto, é importante destacar que o método ainda apresenta algumas desvantagens. Uma delas é a dificuldade em produzir resultados com estruturas de conteúdo completamente preservadas. Isso significa que, em alguns casos, podem ocorrer perdas ou distorções nas informações originais das imagens.

Figura 28 – Imagem de entrada à esquerda, resultado da técnica à direita



Fonte: Men *et al.* (2022, p.3501).

5.12 *GAN-Based Multi-Style Photo Cartoonization*

No trabalho Shu *et al.* (2021), apresentam a *MS CartoonGAN*, uma nova arquitetura de GAN que demonstrou a capacidade de gerar diversos estilos de *cartoons* a partir de uma única imagem de entrada. Nos testes de comparação realizados, a abordagem proposta mostrou-se altamente satisfatória. Uma das principais vantagens da *MS CartoonGAN* é que o treinamento da GAN ocorre apenas uma vez, o que torna o processo mais eficiente. Além disso, o codificador utilizado consegue capturar de forma mais precisa o estilo comum compartilhado por diferentes imagens de desenho animado, resultando em imagens de melhor qualidade. Outro aspecto positivo da arquitetura é a sua extensibilidade para vários estilos. Isso significa que a *MS CartoonGAN* pode ser adaptada para gerar diferentes tipos de *cartoons*, proporcionando uma maior versatilidade no processo de criação (Figura 29).

Figura 29 – Imagem de entrada à esquerda, resultado da técnica à direita



Fonte: Shu *et al.* (2021, p.3384).

5.13 *Learning to Cartoonize Using White-box Cartoon Representations*

No trabalho de Wang e Yu (2020) apresentam uma abordagem para a cartoonização de imagens, a qual se destaca por identificar separadamente três representações: superfície, estrutura e textura. Os resultados obtidos demonstram sua superioridade em relação a outros métodos em todos os casos de teste, sendo capaz de preservar fielmente tanto as informações de conteúdo quanto o estilo da imagem. Uma das principais vantagens dessa abordagem é a

capacidade de gerar imagens com cores harmoniosas e estilos artísticos agradáveis. Além disso, as bordas das imagens são nitidamente definidas e limpas, o que contribui para uma aparência visualmente atraente. Outro aspecto notável é a significativa redução de artefatos indesejados, o que garante a qualidade das imagens cartoonizadas (Figura 30). Outro ponto positivo é a eficiência no processamento das imagens, pois a técnica proposta permite realizar a cartoonização em tempo real. Essa característica é particularmente relevante em aplicações que requerem uma resposta rápida, como em sistemas interativos ou aplicações de tempo real.

Figura 30 – Imagem de entrada à esquerda, resultado da técnica à direita



Fonte: Wang e Yu (2020, p.8095).

5.14 *AI-Enable Generating Human Faces using Deep Learning*

No trabalho de Varshney *et al.* (2023) exploram a área da geração de imagens com estilo *cartoon* a partir de fotografias de rostos. Em seus resultados, os autores demonstram que é possível obter imagens com uma atraente dose de apelo visual, ao mesmo tempo que preservam os principais detalhes da imagem original. Uma das principais vantagens dessa abordagem é a capacidade de gerar imagens persuasivas, capazes de cativar o público de forma eficaz. Além disso, o modelo de GAN utilizado nesse processo demonstrar ser mais rápido, o que representa uma significativa vantagem para aplicações em tempo real. No entanto, como toda tecnologia, há desafios a serem enfrentados. O método apresentado pelos autores possui algumas limitações, resultando em pontos de corte nas imagens geradas e, por consequência, requerendo algumas correções para aprimorar a qualidade do resultado final. Essas correções podem envolver intervenção manual ou ajustes adicionais no modelo, o que pode aumentar o esforço necessário no processo de geração de imagens com estilo *cartoon*.

5.15 *Generating Cartoon Images from Face Photos with Cycle-Consistent Adversarial Networks*

No trabalho de Zhang *et al.* (2023) apresentam um método para transformação de estilo *cartoon* baseado em GAN. Os resultados obtidos nesse trabalho destacam-se pela eficácia do método em diferentes tipos de imagens, como rostos humanos, alimentos, animais e paisagens. Comparado a outras abordagens, o *CBA-GAN* se mostrou capaz de produzir resultados visualmente mais agradáveis, ao mesmo tempo que preserva detalhes importantes da imagem original. Uma das principais vantagens do método proposto é sua capacidade de preservar as bordas, texturas e cores da imagem real, garantindo que a transformação para o estilo *cartoon* não comprometa esses aspectos fundamentais (Figura 31). Além disso, o *CBA-GAN* mantém a essência das sombras presentes na imagem original, enquanto ignora características superficiais que não são essenciais para a representação do estilo *cartoon*.

5.16 *Analysis of Learning Mechanism of Generative Adversarial Network*

No trabalho de Zhang *et al.* (2021), apresentam um método de geração de imagens no estilo *cartoon* de rostos humanos, utilizando as GANs. Nesse trabalho, eles incorporaram um modelo pré-treinado para controlar a perda de conteúdo durante o processo de geração. No

entanto, apesar dos esforços, o resultado final não foi totalmente satisfatório, pois as imagens geradas apresentaram problemas de distorção devido a um colapso na GAN. Entre as vantagens do método proposto, destaca-se o tempo de resposta reduzido, uma vez que o modelo converge de forma mais simples na função de perda. Porém, como mencionado pelo autor, o valor da função de perda tende a cair, levando a distorções nas imagens geradas.

Figura 31 – Imagem de entrada à esquerda, resultado da técnica à direita



Fonte: Zhang *et al.* (2023, p.2741).

5.17 Métricas de avaliação

No Quadro 5, são apresentadas quais métricas foram utilizadas por cada autor para avaliar o desempenho da abordagem desenvolvida:

Quadro 5 – Relação das métricas utilizadas pelos autores.

Nº	Autorias	Análise qualitativa	Análise quantitativo	Estudo de ablação
1	Anand (2022)	Sim	Sim	Não
2	Andersson e Arvidsson (2020)	Sim	Não	Não
3	Chen <i>et al.</i> (2018)	Sim	Não	Não
4	Dong <i>et al.</i> (2021)	Sim	Sim	Sim
5	Gao <i>et al.</i> (2022)	Sim	Sim	Sim
6	Harshitha <i>et al.</i> (2020)	Sim	Sim	Não
7	Hedge <i>et al.</i> (2021)	Não	Sim	Não
8	Ho <i>et al.</i> (2023)	Sim	Sim	Sim
9	Li <i>et al.</i> (2020)	Sim	Sim	Sim
10	Li <i>et al.</i> (2019)	Não	Não	Sim
11	Men <i>et al.</i> (2022)	Sim	Sim	Não
12	Shu <i>et al.</i> (2021)	Sim	Sim	Sim
13	Wang e Yu (2020)	Sim	Sim	Sim
14	Varshney <i>et al.</i> (2023)	Não	Sim	Não
15	Zhang <i>et al.</i> (2023)	Sim	Sim	Sim
16	Zhang <i>et al.</i> (2021)	Não	Sim	Não

Fonte: Elaborado pela Autora (2023).

6 RESULTADOS

Neste capítulo, apresentaremos as respostas às perguntas de pesquisa e a análise dos resultados obtidos por meio da revisão sistemática da literatura.

6.1 Q1 - De que forma as técnicas de transferência de estilo *cartoon* estão sendo usadas para produzir resultados com estilo consistente e expressivo na NPR?

Existem várias abordagens propostas nos artigos revisados para melhorar a transferência de estilo *cartoon* na NPR, com o objetivo de produzir resultados consistentes e expressivos. Uma dessas abordagens destaca-se pelo uso de algoritmos de colisão de textura adaptativa (Figura 32), conforme proposto por Gao *et al.* (2022). Outros estudos, como os de Harshitha *et al.* (2020), Anand (2022) e Wang e Yu (2020), exploram o uso de técnicas de caixa branca para aprimorar os detalhes e a consistência do estilo (Figura 33). Além disso, o método desenvolvido por Li *et al.* (2020) preserva informações detalhadas de saliência ao mapear imagens não pareadas entre domínios de origem e destino (Figura 34), contribuindo para resultados mais fiéis. Men *et al.* (2022) utilizam um modelo de síntese de imagem simples com mapeamento de ciclo fechado (Figura 35). Portanto, todas essas abordagens têm como objetivo melhorar a aplicação das técnicas de transferência de estilo *cartoon*.

6.2 Q2 - Quais métricas foram utilizadas para avaliar a eficiência desses algoritmos/técnicas?

As métricas de avaliação que foram identificadas nos trabalhos para medir a qualidade e eficiência das técnicas de renderização não fotorrealísticas com estilo *cartoon* são: análise qualitativa, análise quantitativa e estudo de ablação.

A análise qualitativa foi utilizada em 12 estudos, representando 36% dos artigos revisados (Figura 36). Nesta métrica, as imagens geradas pelas técnicas são avaliadas visualmente por um público de pessoas. A avaliação é baseada em critérios subjetivos, como, semelhança estilística, expressividade, consistência, preservação de cores, satisfação, dentre outras características. O objetivo dessa avaliação é atribuir pontos positivos à qualidade das imagens geradas e eficácia das técnicas.

A análise quantitativa foi utilizada em 13 estudos, representando 40% dos artigos revisados (Figura 36). Dong *et al.* (2021) discutem a dificuldade de avaliar métodos de transfe-

Figura 32 – Resultados da técnica.



Fonte: Gao *et al.* (2022, p.1).

Figura 33 – Resultado da técnica.




Fonte: Men *et al.* (2022, p.3501).

Figura 34 – Resultado da técnica.



Fonte: Li *et al.* (2020, p.378).

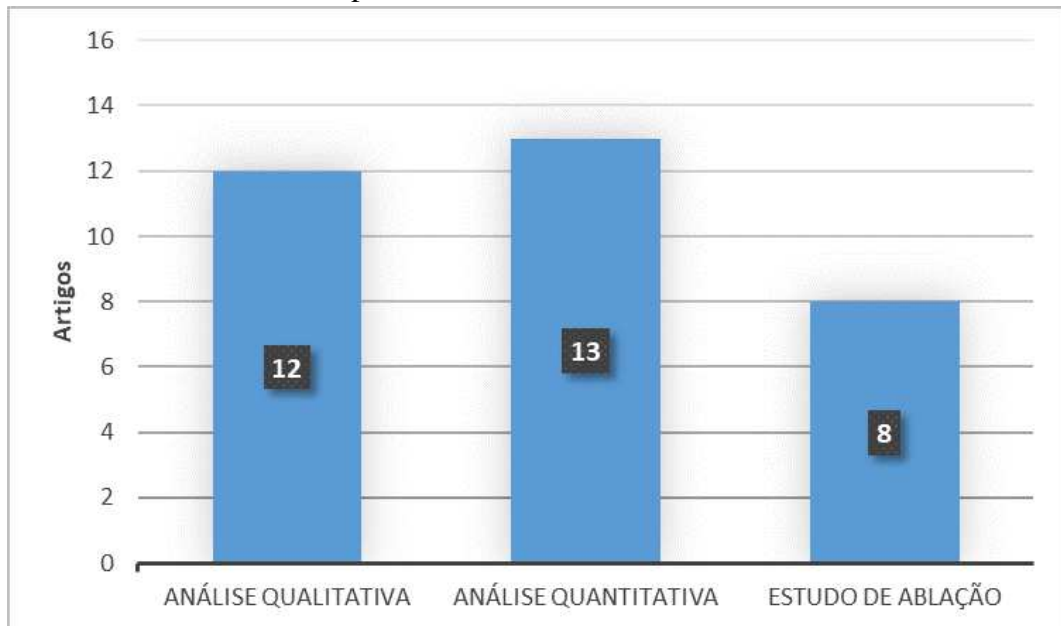
Figura 35 – Resultado da técnica.



Fonte: Wang e Yu (2020, p.8091).

rência de estilo artístico qualitativamente, já que a avaliação das pessoas é muito subjetiva para medir com métricas específicas. Deste modo, os autores priorizam realizar análise quantitativa, por ela buscar avaliar desempenho e qualidade visual da imagem computacionalmente geradas pelas GANs, sendo a mais usada por eles o *Fretchet Inception Distance* (FID), o *Inception Score* (IS) e o *Structural Similarity* (SSIM).

Figura 36 – Métricas utilizadas pelos autores



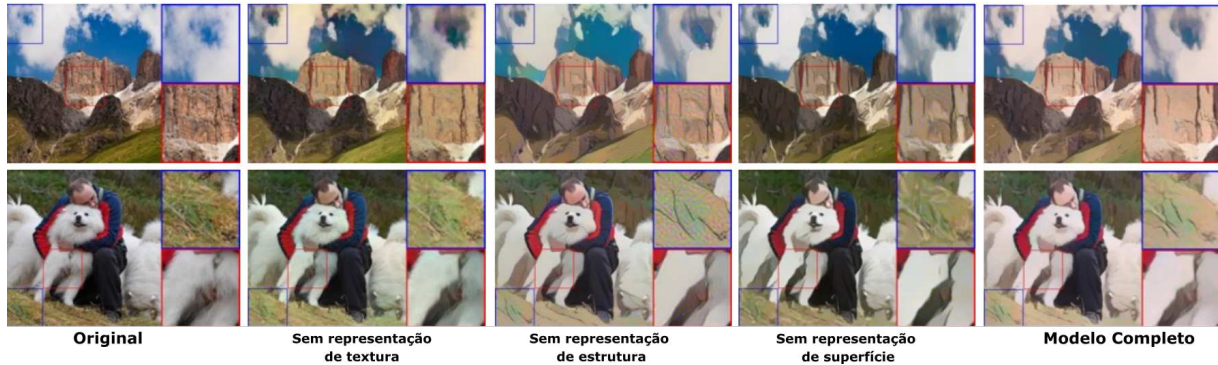
Fonte: Elaborada pela Autora (2023).

O *Inception Score* (IS) foi criado em 2016 para utilizar um modelo pré-treinado para calcular a probabilidade de uma imagem pertencer a uma classe de estilo específica (HO *et al.*, 2023), no entanto, não correspondeu às expectativas, por não retornar resultados ideais ou quantificáveis. Então, em 2017 surgiu o *Fretchet Inception Distance* (FID) que semelhantemente ao IS, utiliza um modelo pré-treinado para extrair recursos de imagem e avaliar a similaridade entre duas distribuições de imagem. Quanto menor a pontuação do FID, mais próximas são as distribuições das imagens geradas em relação às imagens reais de referência (LI *et al.*, 2020; HARSHITHA *et al.*, 2020). Por outro lado, o *Structural Similarity* (SSIM) é uma métrica que fornece uma medida objetiva da semelhança estrutural entre as imagens (HO *et al.*, 2023).

Por fim, o estudo de ablação que foi utilizada por 8 autores, representando 24% dos artigos revisados. Ela é uma métrica que analisa a eficácia relativa de cada componente ou características (textura, superfície, filtros, coloração), visando determinar a contribuição desses componentes na técnica para o funcionamento geral (SHU *et al.*, 2021). Na Figura 37, Wang e Yu (2020) demonstram como funcionou o teste de ablação. Para cada teste, foram removido

representações de textura, estrutura e superfícies, e no fim foi exibido o resultado com todos esses componentes.

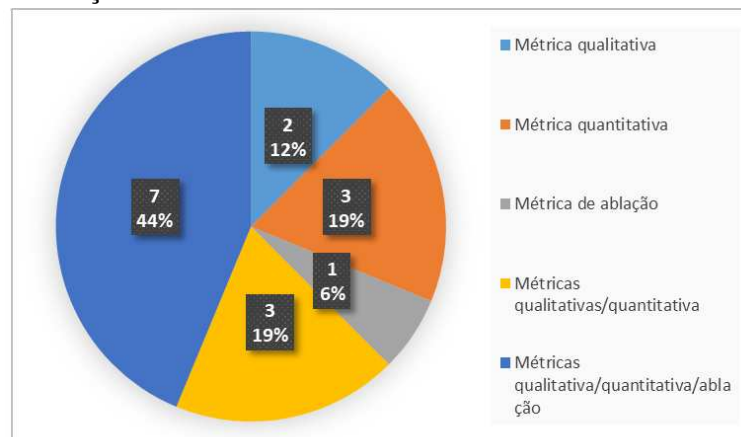
Figura 37 – Resultado de um teste de ablação.



Fonte: Wang e Yu (2020, p.8097).

O gráfico presente na Figura 38 mostra a distribuição de uso das métricas pelos trabalhos observados. De maneira geral, ao analisar ambos os gráficos, fica evidente que a análise quantitativa é a abordagem mais adotada pelos autores.

Figura 38 – Combinação das métricas utilizadas pelos autores para maximizar a avaliação



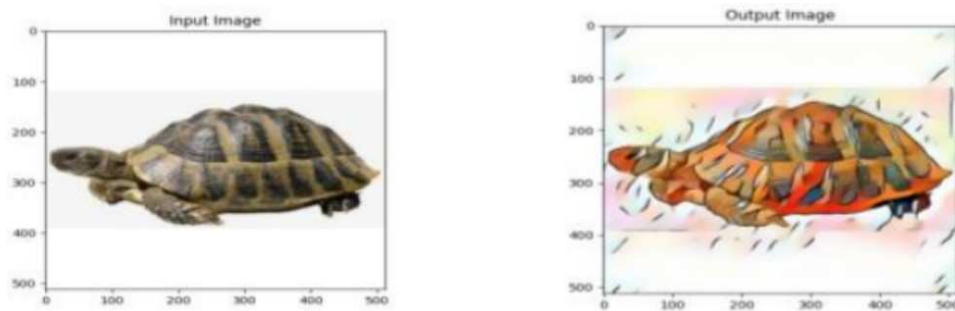
Fonte: Elaborada pela Autora (2023).

6.3 Q3 - Quais são os desafios e as limitações das técnicas de transferência de estilo *cartoon* na renderização não fotorrealística?

Alguns dos desafios na NPR com estilo *cartoon* segundo os autores, incluem desde a captura precisa de características e preservação de detalhes, controle do nível de estilização desejado, ou a eficiência computacional para renderizações em tempo real. Mesmo com os avanços em algoritmos de transferência de estilo que surgem para diminuir essas limitações,

existe uma carência na capacidade de aprendizado baseado em dados necessários para capturar toda a profundidade e diversidade dos estilos do *cartoon* (GAO *et al.*, 2022). Nas Figuras 39 e 40, são mostrados exemplos de imagens distorcidas e que perderam o controle de nível de estilização e preservação.

Figura 39 – Exemplo de um resultado indesejável por conter evidências de artefatos visuais fora do conteúdo original da imagem.



Fonte: Hedge *et al.* (2021, p.3501).

Figura 40 – Exemplos de distorção e não preservação de detalhes.



Fonte: Ho *et al.* (2023, n.p).

Li *et al.* (2020) explicam que um dos problemas observados nas abordagens tradicionais de transferência de estilos é a perda de detalhes em regiões estruturadas e excesso de detalhes em regiões suaves (integridade de detalhes e semântica). Uma possível explicação para esses problemas é a dependência excessiva dos modelos GAN para criar distinções nas regiões da imagem (baixa quantidade de imagens de treinamento (CHEN *et al.*, 2018; HEDGE *et al.*, 2021; SHU *et al.*, 2021)). Então, esse problema envolve encontrar uma abordagem que equilibre a preservação dos detalhes e a suavização. Porém Zhang *et al.* (2021) apresentam que mesmo os pesquisadores resolvendo esse problema, os recursos extras de hardware e de tempo podem


ser considerados como desperdício se não houver uma melhoria significativa na qualidade da imagem gerada. Em alguns casos, o ganho em qualidade pode não ser proporcional ao esforço e aos recursos investidos, resultando em um desperdício de recursos.

6.4 Discussão

Esta revisão sistemática apresentou uma visão geral das técnicas de NPR, destacando as abordagens dos últimos 6 anos, bem como suas vantagens, desvantagens, métricas de avaliação utilizadas e os principais desafios e limitações enfrentados pelos autores. Ao analisar os métodos propostos, é evidente que o uso das GANs traz benefícios como flexibilidade, controle de níveis, preservação do conteúdo semântico, geração de imagens com cores harmoniosas e bordas limpas (Figura 41), além de processamento em tempo real. No entanto, também há desvantagens, como possíveis distorções nas imagens geradas, pontos de corte que exigem correções, dificuldade na preservação completa do conteúdo, mudanças de gradiente não óbvias, dificuldade na detecção de saliência (Figura 42), possibilidade de gerar ruídos e rugas indesejadas (Figura 43). Essas vantagens e desvantagens devem ser consideradas no desenvolvimento de técnicas novas.


Embora os autores tenham apresentado soluções promissoras, é importante ressaltar que elas não estão livres de limitações como a captura precisa de características, a preservação de detalhes, o controle preciso do nível de estilização desejado e a eficiência computacional para renderizações em tempo real.

Figura 41 – Exemplo de um resultado desejável com bordas limpas e harmônicas.




Fonte: Wang e Yu (2020, p.8096).

Figura 42 – Exemplos de detecção de saliência na imagem.



Fonte: Li *et al.* (2020, p.383).

Figura 43 – Exemplo de produção de ruídos na região da testa.



Fonte: Ho *et al.* (2023, n.p).

7 CONCLUSÕES E TRABALHOS FUTUROS

A técnica de transferência de estilo envolve o uso de duas imagens, onde o estilo de uma é aplicado ao conteúdo da outra, resultando na combinação de suas características na imagem final. Neste trabalho, foram apresentados os resultados de uma revisão sistemática da literatura que teve como objetivo realizar um levantamento geral dos desafios na utilização de técnicas de transferência de estilo do *cartoon*. Foram identificados 16 trabalhos que atendem ao tema proposto, de modo que foi possível extrair informações como objetivos, vantagens, desvantagens, métricas utilizadas e conseqüentemente responder às perguntas de pesquisa.

Em suma, os desafios na NPR com estilo *cartoon* incluem a captura precisa de características, preservação de detalhes, controle do nível desejado de estilização e a eficiência computacional para renderizações em tempo real. Apesar dos avanços nos algoritmos de transferência de estilo, ainda há uma carência na capacidade de aprendizado baseado em dados para capturar toda a essência do estilo *cartoon*. Abordagens tradicionais de transferência de estilos enfrentam problemas como a perda de detalhes em regiões estruturadas e o excesso de detalhes em regiões suaves, devido à dependência excessiva de modelos GAN por falta de imagens para treinamento. É crucial considerar que recursos adicionais de hardware e tempo podem não valer a pena se não houver uma melhoria notável na qualidade da imagem produzida, resultando em uma perda desnecessária de recursos, especialmente em aplicações de tempo real como jogos.

Os dados obtidos nessa revisão podem orientar futuros trabalhos nessa área, direcionando esforços para o aprimoramento das técnicas existentes e para a busca por soluções que abordem os desafios mencionados. Diante disto, essas informações podem ser úteis para pesquisadores e desenvolvedores de aplicações. Esta revisão apresenta trabalhos promissores em termos de estilo consistente e expressividade. As técnicas dos trabalhos mostram-se capazes de preservar detalhes importantes e produzir imagens atraentes mesmo com as limitações. No entanto, ainda existem desafios a serem superados. No fim, a metodologia de pesquisa utilizada nesta revisão sistemática pode servir como base para futuras revisões. Como trabalho futuro, esta revisão poderá ser estendida para CNN.

REFERÊNCIAS

- ALBUQUERQUE, M. P. de; ALBUQUERQUE, M. P. de. Processamento de imagens: métodos e análises. **Rio de Janeiro, Brasil**, v. 12, 2000.
- ALBUQUERQUE, V. H. C. d. *et al.* Sistema de segmentação de imagens para quantificação de microestruturas em metais utilizando redes neurais artificiais. **Matéria (Rio de Janeiro)**, SciELO Brasil, v. 12, p. 394–407, 2007.
- ALQAHTANI, H.; KAVAKLI-THORNE, M.; KUMAR, G. Applications of generative adversarial networks (gans): An updated review. **Archives of Computational Methods in Engineering**, [S. l.], Springer, v. 28, p. 525–552, 2021.
- ANAND, S. Effective mode of learning cartonization: White-box cartoon representations. [S. l.], 2022.
- ANDERSSON, F.; ARVIDSSON, S. Generative adversarial networks for photo to hayao miyazaki style cartoons. **arXiv preprint arXiv:2005.07702**, [S. l.], 2020.
- ANDERSSON, S. A. F. **Resultados**. 2020. Disponível em: <<https://github.com/FilipAndersson245/cartoon-gan>>. Acesso em: 23 nov. 2022.
- APRENDIS. **Processamento de Imagem**. 2017. Disponível em: <http://aprendis.gim.med.up.pt/index.php/Processamento_de_Imagem>. Acesso em: 18 nov. 2022.
- ARRUDA, F. d. A. P. V. *et al.* Uma abordagem híbrida para a renderização não fotorrealística de vídeos digitais. **Paraíba**, Universidade Federal de Campina Grande, 2014.
- BARILE, P.; CIESIELSKI, V.; TRIST, K. Non-photorealistic rendering using genetic programming. In: SPRINGER. **Asia-Pacific Conference on Simulated Evolution and Learning**. [S.l.], 2008. p. 299–308.
- CARVALHO, B. M.; NETO, L. B.; OLIVEIRA, L. M. Bottled sand movies. In: IEEE. **International Conference on Computer Graphics, Imaging and Visualisation (CGIV'06)**. [S.l.], 2006. p. 402–407.
- CHEN, Y.; LAI, Y.-K.; LIU, Y.-J. Cartoongan: Generative adversarial networks for photo cartoonization. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. [S.l.: s.n.], 2018. p. 9465–9474.
- DANNER, S. M.; WINKLHOFER, C. J. Cartoon style rendering. In: **Relatório técnico, Universidade Técnica de Viena**. Acedido em <http://www.cg.tuwien.ac.at/courses/Seminar/WS2007/comicstyle.pdf>. [S.l.: s.n.], 2008. v. 14.
- DERMEVAL, D.; COELHO, J. A. d. M.; BITTENCOURT, I. I. Mapeamento sistemático e revisão sistemática da literatura em informática na educação. **JAQUES, Patrícia Augustin; SIQUEIRA; Sean; BITTENCOURT, Ig; PIMENTEL, Mariano.(Org.) Metodologia de Pesquisa Científica em Informática na Educação: Abordagem Quantitativa**. Porto Alegre: SBC, 2020.
- DONG, Y. *et al.* Cartoonlossgan: Learning surface and coloring of images for cartoonization. **IEEE Transactions on Image Processing**, [S. l.], IEEE, v. 31, p. 485–498, 2021.

- EGMONT-PETERSEN, M.; RIDDER, D. de; HANDELS, H. Image processing with neural networks—a review. **Pattern recognition**, [S. l.], Elsevier, v. 35, n. 10, p. 2279–2301, 2002.
- EXPRESS, F. **O que é Pixel? – Definição, RESOLUÇÃO DE IMAGEM E REAMOSTRAGEM!** 2020. Disponível em: <<https://www.futuraexpress.com.br/blog/o-que-e-pixel/>>. Acesso em: 20 nov. 2022.
- FALCÃO, A. X. **Introdução ao processamento de imagem digital**. 2007.
- FILHO, O. M.; NETO, H. V. **Processamento digital de imagens**. [S.l.]: Brasport, 1999.
- FUN, I. L. S. *et al.* Non-photorealistic outdoor scene rendering: techniques and application. In: IEEE. **Proceedings. International Conference on Computer Graphics, Imaging and Visualization, 2004. CGIV 2004**. [S.l.], 2004. p. 215–220.
- GAO, X.; ZHANG, Y.; TIAN, Y. Learning to incorporate texture saliency adaptive attention to image cartoonization. **arXiv preprint arXiv:2208.01587**, [S. l.], 2022.
- GATYS, L. A.; ECKER, A. S.; BETHGE, M. A neural algorithm of artistic style. **arXiv preprint arXiv:1508.06576**, [S. l.], 2015.
- GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais**. [S.l.]: Editora Blucher, 2000.
- GOOCH, B. S. **Human facial illustrations: Creation and evaluation**. [S.l.]: The University of Utah, 2003.
- HARSHITHA, R.; MUTTUR, K. S.; SHETTY, J. Cartooniation using white-box technique in machine learning. [S. l.], 2020.
- HEDGE, M. B. *et al.* Pokégan: P2p (pet to pokémon) stylizer. **SMU Data Science Review**, [S. l.], v. 5, n. 2, p. 10, 2021.
- HO, S.-T. *et al.* Abstraction-perception preserving cartoon face synthesis. **Multimedia Tools and Applications**, [S. l.], Springer, p. 1–18, 2023.
- IME JUNIOR. **Desenho Técnico e Desenvolvimento de Projetos de Mecânica**. 2019. Disponível em: <<https://imejunior.com.br/2016/12/01/desenvolvimento-em-projetos-de-mecanica/>>. Acesso em: 23 set. 2022.
- KITCHENHAM, B.; CHARTERS, S. *et al.* **Guidelines for performing systematic literature reviews in software engineering**. [S.l.]: UK, 2007.
- KYPRIANIDIS, J. E. **Structure adaptive stylization of images and video**. Tese (Doutorado) — Universität Potsdam, 2013.
- LI, R. Image style transfer with generative adversarial networks. In: **Proceedings of the 29th ACM International Conference on Multimedia**. [S.l.: s.n.], 2021. p. 2950–2954.
- LI, R. *et al.* Sdp-gan: Saliency detail preservation generative adversarial networks for high perceptual quality style transfer. **IEEE Transactions on Image Processing**, [S. l.], IEEE, v. 30, p. 374–385, 2020.

- LI, X. *et al.* Everyone is a cartoonist: Selfie cartoonization with attentive adversarial networks. In: IEEE. **2019 IEEE international conference on multimedia and expo (ICME)**. [S.l.], 2019. p. 652–657.
- MEN, Y. *et al.* Unpaired cartoon image synthesis via gated cycle mapping. In: **Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition**. [S.l.: s.n.], 2022. p. 3501–3510.
- MOURA, J. C. da C. Técnicas de limiarização em imagens de retinografia. [S. l.], 2018.
- NETO, L. d. S. B. **Renderizações não fotorealísticas para estilização de imagens e vídeos usando areia colorida**. Dissertação (Mestrado) — Universidade Federal do Rio Grande do Norte, 2007.
- PANG, Y. *et al.* Image-to-image translation: Methods and applications. **IEEE Transactions on Multimedia**, [S. l.], IEEE, v. 24, p. 3859–3881, 2021.
- SHU, Y.; YI, R.; XIA, M.; YE, Z.; ZHAO, W.; CHEN, Y.; LAI, Y.-K.; LIU, Y.-J. Gan-based multi-style photo cartoonization. **IEEE Transactions on Visualization and Computer Graphics**, [S. l.], IEEE, v. 28, n. 10, p. 3376–3390, 2021.
- SINGH, A. *et al.* Neural style transfer: A critical review. **IEEE Access**, [S. l.], IEEE, v. 9, p. 131583–131613, 2021.
- THAKUR, A.; RIZVI, H.; SATISH, M. White-box cartoonization using an extended gan framework. **arXiv preprint arXiv:2107.04551**, [S. l.], 2021.
- VARSHNEY, N. *et al.* Ai-enable generating human faces using deep learning. In: IEEE. **2023 IEEE 12th International Conference on Communication Systems and Network Technologies (CSNT)**. [S.l.], 2023. p. 256–262.
- WANG, X.; YU, J. Learning to cartoonize using white-box cartoon representations. In: **Proceedings of the IEEE/CVF conference on computer vision and pattern recognition**. [S.l.: s.n.], 2020. p. 8090–8099.
- WIKIPEDIA. **Visualização de dados**. 2021. Disponível em: <https://en.wikipedia.org/wiki/Scientific_visualization>. Acesso em: 23 set. 2022.
- WIKIPEDIA Updit Da. **Renderização fotorrealística**. 2021. Disponível em: <https://pt.upwiki.one/wiki/Non-photorealistic_rendering>. Acesso em: 23 set. 2022.
- WIKIPÉDIA, a. E. L. **Cartoon**. 2022. Disponível em: <<https://pt.wikipedia.org/wiki/Cartoon>>. Acesso em: 23 set. 2022.
- ZENG, K.; ZHAO, M.; XIONG, C.; ZHU, S. C. From image parsing to painterly rendering. **ACM Trans. Graph.** [S. l.], v. 29, n. 1, p. 2–1, 2009.
- ZHANG, F. *et al.* Cba-gan: Cartoonization style transformation based on the convolutional attention module. **Computers and Electrical Engineering**, [S. l.], Elsevier, v. 106, p. 108575, 2023.
- ZHANG, T. *et al.* Generating cartoon images from face photos with cycle-consistent adversarial networks. **Computers, Materials and Continua**, [S. l.], Computers, Materials and Continua (Tech Science Press), 2021.

ZHAO, Y. *et al.* Cartoon image processing: A survey. **International Journal of Computer Vision**, [S. l.], Springer, v. 130, n. 11, p. 2733–2769, 2022.