

O modelo de inteligência artificial adversarial generativo na criação de *assets* em duas dimensões para artistas de jogos digitais

The generative adversarial artificial intelligence model in the creation of two-dimensional assets for digital game artists

Jefferson VALENTIM¹
Ed Porto BEZERRA²

Resumo

O objetivo deste artigo é analisar o potencial da inteligência artificial (IA) como uma ferramenta artística para construir *assets* em duas dimensões para jogos digitais. Para tanto foi feita uma pesquisa utilizando o modelo de IA generativo adversarial na construção de *assets* em duas dimensões. Nela foram adotados o método científico indutivo e o estudo de caso. O resultado obtido foi que o modelo de IA pode construir novas imagens a partir de banco de dados imagéticos. Isso significa que o modelo tem o potencial de criar novos *assets* a partir de uma base de dados pré-definida pelo artista e pode ser utilizado como uma ferramenta para automatizar a criação artística de *assets*.

Palavras-chaves: Jogos digitais. Redes adversárias generativas. *Assets*. Artes.

Abstract

The purpose of this article is to analyze the potential of artificial intelligence - AI as an artistic tool to build two-dimensional assets for digital games. For that, research was carried out using the adversarial generative AI model in the construction of assets in two dimensions. It adopted the inductive scientific method and the case study. The result obtained was that the artificial intelligence model can build new images from image databases. This means that the model has the potential to create new assets from a predefined database by the artist and can be used as a tool to automate the artistic creation of assets.

Keywords: Digital games. Generative adversarial networks. *Assets*. Art.

¹ Mestrando no Programa de Pós-graduação em Comunicação e Artes da Universidade Federal da Paraíba (PPGCCA/UFPB). E-mail: jeffersonvalentim2014@gmail.com

² Professor Doutor do Programa de Pós-graduação em Computação, Comunicação e Artes pela Universidade Federal da Paraíba (PPGCCA/UFPB). E-mail: edporto@di.ufpb.br

Introdução

Estima-se que a indústria de jogos digitais continuará expandindo nos próximos anos, ultrapassando 200 bilhões dólares até final de 2023 (PACETE, 2022). Nos últimos anos, os jogos digitais movimentaram 175,8 bilhões de dólares. Eles tiveram uma ascensão vertiginosa durante a pandemia do Sars-Cov-2 (BULHÕES, 2022). Esse fenômeno ocorreu devido ao isolamento social e a diversificação de gêneros dos jogos digitais.

Os jogos digitais em duas dimensões terão uma boa participação nessa evolução (IBIDEM, 2022). Jogos como *My Master Wars*, *Osiris Game*, *Crypto Raiders Game*, *Reward Hunters*, *Chicken Derby*, *Block Creatures*, *Crypto Drake Ball*, *Binamars*, *Axie Infinity Game* que movimentam juntos bilhões de dólares. Nesse perspectiva, a indústria dos jogos de duas dimensões - 2D cresce e diversos estúdios são criados em todo o mundo.

O aumento na popularidade dos jogos digitais e a expansão da indústria abriu espaço para novos estúdios digitais surgirem no Brasil. Esses estúdios estão produzindo cada vez mais jogos devido à alta possibilidade de rentabilidade e com isso geram uma alta demanda para o artista que cria *assets*. Os *assets* são ativos artísticos que compõem o arcabouço estético do jogo. Eles são elementos produtores de sentido no jogo e são um dos pilares para os jogos digitais que dependem de uma estrutura visual para sua compreensão/representação.

A arte nos jogos digitais desempenha um papel fundamental e recursos que promovem a ampliação do horizonte produtivo do artista podem ser utilizados como extensão humana no processo de produção. Desse modo, programas de computador são capazes de criar material pictórico abundante e possibilitam uma variedade de material artístico para utilização nos jogos digitais. Um modelo que tem a capacidade de criar imagens a partir de um banco de dados. Esse banco de dados pode ser construído por imagens de diferentes gêneros escolhidas pelo artista. Nesse contexto, o artigo objetiva analisar o potencial do modelo de redes adversárias generativas como uma ferramenta artística para construir *assets* em duas dimensões para jogos digitais.

O artigo usa um conjunto de *assets* em duas dimensões para compor um estudo de caso e gerar as inferências. Nessa perspectiva, é feito um percurso teórico acerca dos temas em foco e uma simulação do modelo. Por meio do percurso teórico e da simulação são geradas inferências indutivas do potencial do modelo como uma ferramenta para o

artista. Essas inferências demonstram que o modelo tem o potencial de automatizar a produção artística ao gerar imagens criadas com cores e traços diferentes.

O trabalho está dividido em quatro partes. Na primeira é discutido o percurso utilizado para elaboração da pesquisa. Na segunda é abordada a fundamentação teórica. Na terceira é realizada a análise da arquitetura do modelo adversária generativo e na quarta são demonstrados os resultados com as inferências das observações na conclusão.

Procedimentos metodológicos

O trabalho está inserido dentro de uma abordagem indutiva em que o fenômeno empírico é observado em suas relações e depois são construídas as conjecturas que contribuem para a solução do problema (DRESCH et al., 2020; GIL, 2022). Desse modo, o método científico foi escolhido por possibilitar a formulação de inferências a respeito do que está sendo pesquisado e a solução da problemática.

Outro método de pesquisa adotado foi o estudo de caso. Este método é utilizado em pesquisas empíricas que buscam melhor compreender um fenômeno contemporâneo, normalmente complexo, no seu contexto (DRESCH et al., 2020; GIL, 2022). Ele consiste no estudo profundo e exaustivo de um ou poucos casos, de maneira que permite seu amplo e detalhado conhecimento (GIL, 2022).

A associação de ambos os métodos foi devido à natureza indutiva do estudo. Uma das razões para tal associação é o ponto de partida da pesquisa, uma vez que o estudo de caso parte de observações e análises de fenômenos reais (DRESCH et al., 2020; GIL, 2022). Outra razão é o fato de o método científico pressupor a geração de teorias, o que é, inclusive, um dos objetivos do estudo de caso. Dessa forma, não há impedimento à utilização do estudo de caso para testar teorias e hipóteses junto ao método científico escolhido (DRESCH et al., 2020).

Ademais, foi utilizado o método de trabalho denominado de observação direta. Essa técnica permitiu analisar os resultados do estudo (DRESCH et al, 2020). Com ela foi possível analisar os dados gerados no estudo para fazer as inferências do pensamento indutivo.

Em um primeiro momento da construção do artigo foi a observação dos alicerces que fornecem suporte ao tema em foco. Dessa forma, foi observada a estrutura da arte imagética, *assets* e dos jogos digitais, assim como a arquitetura das redes adversárias

generativas. As estruturas que possibilitam a criação e discriminação de imagens em sua composição.

Em seguida foi realizada uma consulta à literatura existente acerca do tema e a demarcação dos limites da investigação (DRESCH et al., 2020; GIL, 2022). Assim, foram consultados livros e artigos que norteiam a pesquisa. Então foram consultadas as seguintes referências bibliográficas: Goodfellow et al. (2014), Duarte (2012), Leiser (2009), Russel e Norving (1995), Mextz et al. (2016), Kaust et al. (2019), Jo (2021), Willrich (2000), Anderson e Bavelier (2011).

Na segunda etapa foi realizado o planejamento dos estudos de caso (DRESCH et al., 2020). Nele foi definido qual modelo de inteligência artificial seria utilizado e os *assets* visuais que seriam usufruídos como banco de dados. Nesse contexto, o modelo escolhido foi o de Goodfellow (Goodfellow et al., 2014) e foram escolhidos *assets* em duas dimensões de 32x32 pixels de arco-flechas.

Na quarta etapa da pesquisa foi realizada a condução do teste piloto (DRESCH et al., 2020). No teste foi utilizado a aplicação junto com os *assets* visuais coletados. Em seguida foram coletados os resultados e analisados para serem utilizados para gerar as inferências.

Na quinta etapa foram propostas as inferências para a problemática apresentada no trabalho. Nesse caso, pode-se inferir que sendo os *assets* 2D imagens e que as redes adversárias (GAN) criam infinitas imagens a partir de um banco de dados imagéticos. Logo é possível verificar que as GANs criam diversos *assets* para serem utilizados pelos artistas, assim mostrando seu potencial de automatizar a produção.

Da Arte à Inteligência Artificial

A arte digital é uma disciplina que incorpora todas as manifestações artísticas realizadas por um computador ou dispositivo tecnológico (LEISER, 2009). Ela está diretamente ligada a representações digitais feitas a partir de dígitos binários - bits. Os bits são a menor unidade de informação que pode ser armazenada ou transmitida por um computador. Eles são representações numéricas de dois valores: 0 e 1, e por meio da manipulação deles e seus múltiplos em bytes, kilobyte (kb), megabyte (Mb), gigabyte (Gb), terabyte (Tb) que é possível pensar a raiz da arte digital.

A raiz da arte digital concatena em grande medida três ciências. A arte com seus objetos essencialmente sensoriais, particulares e que tem peculiaridades de várias ordens (DUARTE, 2012), a ciência com práticas sistemáticas e exploração, bem como, a tecnologia que detém um conjunto de técnicas, habilidades, métodos e processos para produção de artefatos. Nesse contexto, ela concatena arte, ciência e tecnologia para produzir um novo tipo de manifestação que lhe é própria.

As manifestações artísticas digitais possuem particularidades específicas de construção. Por um lado, ela possui as características do meio artístico conceitual, e por outro, uma linguagem visual midiática específica ou plural (LEISER, 2009). Nessa conjuntura, a arte digital possui variadas formas de produção e representação e uma delas é o e-game.

Os e-games são uma das manifestações artísticas mais complexas do século XXI. Eles são criações multimidiáticas desenvolvidas para sistemas digitais diversificados (VALENTIM, 2021). Os e-games são compostos de som, imagem, roteiro, história, mecânicas e elementos discursivos que compõem uma manifestação artística única para o usuário (ANDERSON & BAVELIER, 2011; VALENTIM, 2021). Nesse caso, eles são um conjunto de representações artísticas criadas em um computador por diversos artistas.

A criação de um e-game possui uma grande demanda. Essa demanda é de várias ordens, mas em especial de criação de arte imagética, ou seja, cenários, personagens, itens, mapas e outros elementos que compõem o jogo. Nesse contexto, a produção de arte imagética para os e-games possui grande relevância.

A produção de arte imagética para e-games é feita de forma manual. Nela, o artista desenha os personagens, cenários e itens utilizando softwares. Esses softwares vão compondo as imagens digitalmente em bitmaps (WILLRICH, 2000).

Os bitmaps são matrizes bidimensionais e espaciais compostas de pixels. Esses pixels são o menor elemento de resolução da imagem representados por bits (WILLRICH, 2000; HAVALDAR & MEDIONI, 2010). Os bits na imagem são elementos estruturantes. Elementos que possuem a função de representar os valores de tons e cores que compõem a imagem (WILLRICH, 2000), bem como, os que a modificam. Nesse perspectiva, a imagem pode ser compreendida como uma matriz numérica composta de bits e seus múltiplos.

A geração de imagens no campo da computação está inserida na computação gráfica. Essa área empenha-se na construção de representações imagéticas do mundo real ou fantasias, assim como, de informações e dados. Ela destina-se ao melhoramento da qualidade de imagens e sua produção. Nesse contexto, ela também se ocupa no desenvolvimento de dispositivos de interação humano-computador (monitores, mouses, teclados), bem como os mais diversificados softwares utilizando até aprendizado de máquina.

O aprendizado de máquina pode ocorrer por três vias. O aprendizado supervisionado, o não supervisionado e o aprendizado por reforço. O aprendizado supervisionado é o paradigma de aprendizagem onde os parâmetros são otimizados de forma rotulada para minimizar a diferença entre a saída de destino e a saída computada (JO, 2021). O aprendizado não supervisionado é um aprendizado não rotulado em que o processo não possui uma supervisão humana e o aprendizado por reforço é um tipo aprendizado em que o agente inteligente aprende por meio da atualização de parâmetros para maximização de recompensa e minimizar de penalidade para exercer uma função (JO, 2021). Essas formas de aprendizagem são utilizadas em modelos inteligências artificiais para melhoramento do processo de criação de imagens e um desses modelos é o de redes adversárias generativas.

O modelo de redes adversárias generativas (GAN) funciona por meio de um processo de criação de imagem de forma autônoma. Desse modo, elas funcionam por um processo não supervisionado de criação. Conforme Goodfellow et al. (2014) as GANs criam imagens de forma autônoma por um processo com base na aprendizagem adversarial entre as duas redes, uma geradora e uma discriminadora.

A rede geradora exerce a criação de imagem por meio de um banco de dados. Esse banco de dados é composto por imagens que podem ser compreendidas com matrizes numéricas que é utilizado para gerar as primeiras imagens que serão enviadas para a rede discriminadora. Desse modo, as redes geradoras atuam na criação de imagens falsas a partir de um banco de dados e as envia para a rede discriminadora. (KWAK e KO, 2020).

A rede discriminadora empenha-se na distinção e reconhecimento das imagens enviadas pela a rede geradora. Nesse sentido, ela vai buscar semelhanças nas imagens geradas com as com base em dados de imagens que ela possui (KWAK e KO, 2020) para gerar um resultado sejam conclusivos ou que seja utilizado no *backpropagation* e ajuste dos pesos.

Nesse sentido, as redes adversárias generativas vão aprimorando-se ao decorrer de sua utilização. Tal fenômeno ocorre devido a um conjunto de parâmetros que são enviados da rede discriminadora para a geradora. Esse conjunto é enviado para balancear os pesos. Nesse perspectiva, a cada utilização das redes que é denominado de época, as imagens serão criadas de formas diversificadas e cada vez mais com um sentido estético significativo aos do treinamento da rede geradora.

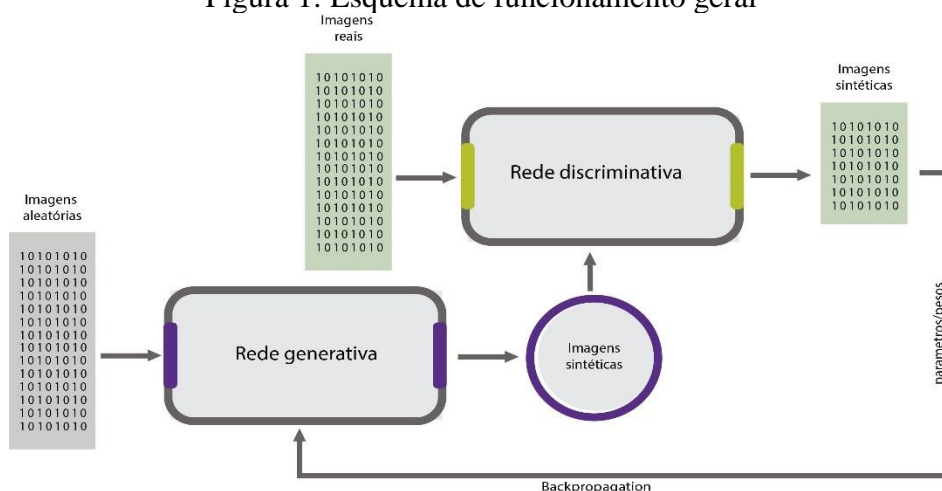
Prova de Conceito

Criada por Goodfellow et al. (2014), a GAN funciona por meio de um processo de criação de imagem de forma autônoma, ou seja, funciona por um processo não supervisionado de criação. Nela é inserido um conjunto de dados reais (imagens) do que se espera da GAN e um conjunto de dados aleatórios (imagens aleatórias) que ao passar das épocas serão fatorados pela rede geradora a fim de se aproximarem dos dados reais.

Nessa perceptiva, a rede geradora exerce a criação de imagem por meio de um banco de dados. Esse banco de dados é composto por imagens que podem ser compreendidas como matrizes numéricas que são utilizadas para gerar as primeiras imagens enviadas para a rede discriminadora. Essas imagens são imagens sintéticas criadas para enganar a rede discriminadora. (KWAK e KO, 2020).

A rede discriminadora recebe as imagens e dedica-se na diferenciação e reconhecimento das imagens. Ela analisa as semelhanças nas imagens geradas com base em dados de imagens reais que ela possui (KWAK e KO, 2020). Identificadas as semelhanças, ela retorna como saída um conjunto de imagens e realizar o envio de conjuntos de parâmetros para camadas anteriores recalcularem os parâmetros, assim fazendo *backpropagation* para a rede geradora criar novas imagens (Figura 1).

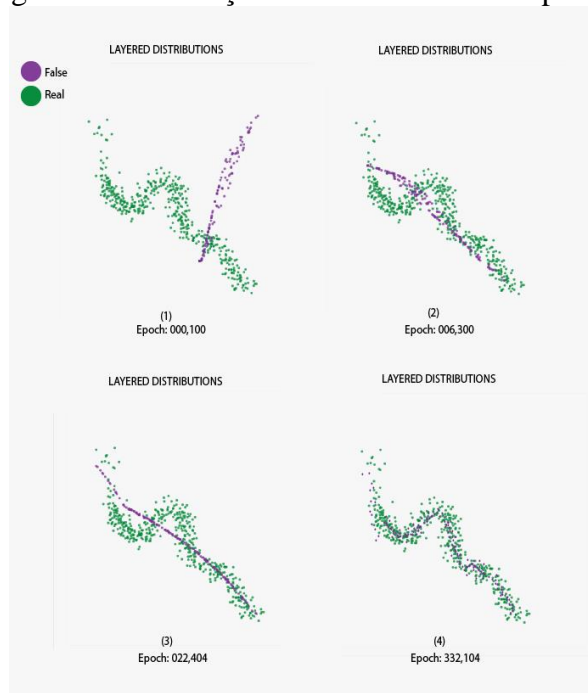
Figura 1: Esquema de funcionamento geral



Fonte: produzido pelo autor

Na figura é mostrada a estrutura de funcionamento do modelo. Nela é possível visualizar um conjunto de passos que a rede utiliza para criar novas imagens a cada época. As imagens serão criadas, a cada época, de formas diversificadas e cada vez mais com um sentido estético e significativo mais próximo das imagens reais. Um exemplo desse processo de treinamento e aproximação das imagens sintéticas das reais pode ser visto na Figura 2.

Figura 2: Distribuição de dados em várias épocas.



Fonte: produzida pelo autor.

Os pontos correspondem a um conjunto de amostras reais e um conjunto de falsos que com o passar das épocas vão assemelhando-se aos reais. Durante o treinamento, um conjunto de amostras reais são representadas por pontos verdes e os ruídos (imagens falsas) por pontos roxos. Nesse processo, a cada época ultrapassada, o conjunto de ruídos aproxima-se dos dados reais no espaço latente. Esse fenômeno representa o aprendizado das características intrínsecas aos dados reais que a rede geradora aprendeu para gerar novas amostras similares.

As amostras geradas possuem as caracterizações dos dados reais. Essas caracterizações (formas, cor, brilho e sombras) dependem da aproximação dos pontos no espaço latente do treinamento. Desse modo, quanto mais distante os pontos roxos estiverem dos verdes, maior será a diferença das imagens geradas. Um exemplo desse fenômeno é mostrado na Figura 3.

Figura 3: Resultados variados.



Fonte: produzido com base em Kaust et al. (2019).

Nela é possível visualizar o resultado de pontos distantes no espaço e suas características com os demais por meio de imagens faciais. É possível notar que há uma variação que advém dos distanciamentos dos pontos no espaço e por meio dele se tem um conjunto de imagens diversificadas. Outro exemplo do seu potencial de criação diversificado pode ser visto na Figura 4. Nela a modelo cria diversos personagens em 2D.

Figura 4: Imagens de personagens variados feitos em 50 épocas.



Fonte: produzido com base em JAIN (2019).

Os personagens criados na imagem fazem parte de um mesmo grupo de amostras, porém as características são diferentes. Desse modo, a cor, a forma e posição dos traços variam em cada imagem, mas todas as imagens continuam sendo de personagens 2D. Durante o processo de criação há uma grande quantidade de criações possíveis e com significados que são geradas pelo modelo de rede a depender do seu usuário.

As imagens geradas pelo modelo podem ser de vários formatos. Elas podem ser de pessoas, animais, objetos e até de parte de cômodos domiciliares. Um exemplo pode ser visto na Figura 5.

Figura 5: Criação de quartos a partir das Gans.



Fonte: Mextz et al (2016).

Nela há diversas imagens de cômodos gerados por um modelo generativo proposto por Mextz et al. (2016).

Nesse caso, as GANs aprenderam o padrão imagético proposto pelo artista e criaram diversos outros a partir do padrão utilizado. Dessa forma, é possível notar a habilidade do modelo em criar novas imagens a partir de um banco de dados imagéticos.

Partindo do modelo de algoritmo proposto Goodfellow et al (2014), foi feito um estudo da rede usando os dados *assets* 2D de arcos-flecha de 32x32 *pixels*. Algumas dessas imagens podem ser vistas na Figura 6.

Figura 6: Imagens utilizadas no banco de dados.



Fonte: produzida pelo autor.

As imagens da Figura 6 são *assets* de e-jogos. Esses *assets* são modelos de arco-flecha utilizados em jogos de duas dimensões. Eles foram utilizados como parâmetros reais para treinar a rede discriminadora. Esse treinamento ocorreu para que o modelo aprendesse as características desejadas para fazer a distinção das imagens criadas pelo gerador.

A outra rede criou, a partir de ruídos, diversos modelos de *assets* 2D. Esses modelos foram melhorando com o passar das épocas e analisados pelo discriminador (Figura 7).

Figura 7: *Assets* criados pelo modelo generativo.



Fonte: produzida pelo autor.

Os *assets* da Figura 7 fazem parte do grupo de amostras artificiais criadas pela rede geradora. Eles são arco-flechas de diferentes formas criados com base no conjunto de características das amostras reais, porém com definições diferentes. Desse modo, a cor, a forma e posição dos traços variam em cada imagem, mas todas as imagens continuam sendo de arcos-flecha em 2D. Nessa perspectiva, durante o processo de criação há uma grande quantidade de criações possíveis que podem ser utilizadas pelo artista.

Considerações finais

Analisou-se o potencial modelo de redes adversárias generativas como uma ferramenta artística para construir *assets* em duas dimensões para jogos digitais. Fez-se um percurso teórico do conceito dos temas em foco envolvendo da Arte Digital até as funcionalidades do modelo GAN e simulação. Por meio desse percurso descobriu-se que o modelo tem um potencial de criar imagens com traços semelhantes às usadas no banco de dados. Esse fenômeno possibilita o modelo criar imagens dentro de uma significância estética. Uma significância que se situa nas características e traços similares aos do grupo de amostra usado no treinamento.

Outro elemento descoberto do potencial do modelo como ferramenta é a capacidade de produzir diversas imagens. Essas imagens que são geradas no funcionamento da GANs podem ser utilizadas para inspirar novos *assets* ou serem utilizados como modelo final. Essa habilidade do modelo, tem potencial para ser bastante utilizada na contemporaneidade. Isso devido à grande demanda por *assets* que os jogos digitais possuem.

Existe demanda por material artístico único que possa ser diferente dos outros, mas sem perder o estilo artístico do game. Nessa perspectiva, o modelo poderia criar diversos *assets* para um jogo no estilo que o artista utiliza.

Ademais, é possível inferir que o modelo tem o potencial de automatizar a produção artística para jogos. A produção de objetos artísticos imagéticos que precisam ser produzidos em larga escala e de forma inteligente para serem utilizados na indústria. Uma indústria que cada vez mais utiliza tecnologias disruptivas para produzir jogos de forma competitiva e esteticamente atraente para o jogador. Em suma, o modelo conceitual de redes adversárias generativas possui o potencial de criar novos *assets* 2D diversificados para artistas que atuam na indústria atual dos jogos digitais, assim como

para artistas que buscam apenas novas ferramentas para criarem novos materiais para jogos pessoais.

Referências

ANDERSON, A. F.; BAVELIER, D; Action game play as a tool to enhance perception, attention and cognition. In: TOBIAS, S.; FLETCHER, J.D. (ed). **Computer games and instruction**. United States of American: Information Age Publishing, 2001.

BULHÕES, G. **Até 2023, o mercado de games pode somar mais de US\$ 200 bilhões**. Olhar digital, São Paulo. 4 de jan. de 2022. Disponível em :<<https://olhardigital.com.br/2022/01/04/pro/ate-2023-mercado-de-games-pode-somar-mais-de-us-200-bilhoes/>>. Acesso em: 6 de jan. de 2022.

COLTON, S.; WIGGINS, G. A. Computational Creativity: The Final Frontier. In: XX European Conference on Artificial Intelligence, 2012, França. In: **Anais do XX ECAI**, França, 2012.

DRESCH, A.; LACERDA, P. D. JÚNIOR, A. V. A. J. **Design Science Research: Métodos de pesquisa para avanço da ciência e tecnologia**. Porto Alegre: Bookman, 2020.

DUARTE, R. **A arte**. São Paulo, Martins fontes. 2012.

HAVALDAR, P.; MEDIONI, G. **Multimedia systems: algorithms, standards, and industry practice**. Boston: Course Technology, 2020.

GALANTER, P. What is Generative Art? Complexity theory as a context for art theory. In: International Conference on Generative Art, 2003, Italy. **Proceedings of the International Conference on Generative Art**, Italy, 2003.

GOODFELLOW, J. I.; ABADIE, P. J.; MIRZA, M.; XU, B.; FARLEY, W. D.; ORZAI, S.; COURVILLE, A.; BENGIO, Y. Generative Adversarial Nets. **ArXiv**, Ithaca, jun. 2014.

GUI, J.; SUN, Z.; WEN, Y.; TAO, D.; YE, J. A Review on Generative Adversarial Networks: Algorithms, Theory, and Applications. **ArXiv**, Ithaca, jan. 2020.

GIL, A. C. **Como elaborar projetos de pesquisa**. São Paulo, Atlas.2022.

JO, T. **Machine learning foundations: supervised, unsupervised, and advanced learning**. Alemanha: Springer, 2021.

JAIN, M. **AnimeGAN conditional**. Github. 2019. Disponível em: <<https://github.com/Natsu6767/Conditional-AnimeGAN/commits?author=Natsu6767>>. Acesso em: 3 de nov de 2021.

LEMOS, F. C.; OLIVEIRA, M. A. Gamearte: a relação jogo/arte e o espaço da mídia no sistema. In: Simpósio Internacional de Mídias Interativas, 2018, Goiana, **Anais do V Simpósio Internacional de Inovação em Mídias Interativas**, Goiana, 2018.

LEISER, W. **Arte digital**. Portugal: Ed.H.F. Hullmann. 2009.

MCCARTHY, J. **What is artificial intelligence**. 1998. Disponível em: <http://www.fredbf.com/disciplinas/unibrathec/dsi/whatisai.pdf>. Acesso em: 27 abr 2021.

MEXTZ, L.; CHINTALA, S.; RADFORD, A.; Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks. **ArXiv**, Ithaca, jan. 2016.

PACETE, G. L. **2022 promissor**: mercado de games ultrapassará US\$ 200 bi até 2023. Forbes, São Paulo, 3 de jan. de 2022. Disponível em: <<https://forbes.com.br/forbes-tech/2022/01/com-2022-decisivo-mercado-de-games-ultrapassara-us-200-bi-ate-2023/>>. Acesso em: 6 de jan. de 2022.

ROSCOE, H. **Arte generativa**: contracenando com a máquina. in: Design: arte, ciência e tecnologia: Conexões teórico-práticas, Rio Grande do Sul: Editora PPGART, 2017.

SIMON, H. A. **The sciences of the artificial**. 3. ed. Cambridge: MIT Press. 1996

RUMELHART, D.; MCCLELLAND, J; **Parallel distributed processing**: explorations in the microstructure of cognition. MIT Press, 1986.

KARRAS, T.; AILA, T.; LAINE, S.; LEHTINEN, J. Progressive Growing of GANs for Improved Quality, Stability, and Variation. **ArXiv**, Ithaca, fev. 2018.

KAUST, R. A.; KAUST, Y. Q.; KAUST, P.W.; Image2StyleGAN: How to Embed Images Into the StyleGAN Latent Space. **ArXiv**, Ithaca, jan. 2019.

VALENTIM, J. Jogos digitais: jogo educativo como ferramenta de construção de significados para o conteúdo escolar. **Temática**. vol. 17, no. 10, pp. 241-242, 20 de out. de 2022.

WILLRICH, R. **Sistemas multimídia distribuídos**. Florianópolis: UFSC, 2000.