

DOSSIÊ

Narrativas de IA: tendências da  
produção audiovisual



V. 15 – N. 1 - jan./abr. 2024

ISSN: 2179-1465 / <https://www.revistageminis.ufscar.br>

DOI: <https://doi.org/10.14244/2179-1465.RG.2024v15i1p115-138>

## INTELIGÊNCIA ARTIFICIAL E ARTE: O MODELO CONCEITUAL DE REDES ADVERSÁRIAS GENERATIVAS NO PROCESSO CRIATIVO DE ARTE PARA JOGOS DIGITAIS

ARTIFICIAL INTELLIGENCE AND ART: THE CONCEPTUAL MODEL OF  
GENERATIVE ADVERSARIAL NETWORKS IN THE CREATIVE PROCESS OF ART  
FOR DIGITAL GAMES

INTELIGENCIA ARTIFICIAL Y ARTE: EL MODELO CONCEPTUAL DE REDES  
ADVERSARIAS GENERATIVAS EN EL PROCESO CREATIVO DE ARTE PARA  
JUEGOS DIGITALES

**Jefferson Valentim**

Universidade Federal da Paraíba (UFPB)  
ORCID: <https://orcid.org/0000-0001-8782-1490>  
João Pessoa, PB, Brasil

**Ed Porto Bezerra**

Universidade Federal da Paraíba (UFPB)  
ORCID: <https://orcid.org/0000-0003-4772-9870>  
João Pessoa, PB, Brasil

Recebido: 15/10/2023 / Aprovado: 03/02/2024

Como citar: VALENTIM, J.; BEZERRA, E. P. Inteligência Artificial e Arte: o modelo conceitual de redes adversárias generativas no processo criativo de arte para jogos digitais. Revista GEMInIS, v. 15, n. 1, p. 115–138, 2024.

Direito autoral: Sob a Licença Creative Commons-Atribuição 3.0 Internacional.



## RESUMO

A interação entre a Inteligência Artificial (IA) e a arte mostrou-se uma área promissora no contexto do processo criativo contemporâneo. Neste artigo, explorou-se como o modelo de redes adversárias generativas (GAN) poderia contribuir na construção de *assets* em duas dimensões (2D) para artistas de jogos digitais. Para atingir esse objetivo, realizou-se uma revisão da literatura e um estudo de caso com *assets* 2D do jogo *Axie Infinity*. Descobriu-se, por meio da pesquisa, que o modelo sintetizava novas imagens que se situavam nas características e traços similares aos do grupo de dados usado no treinamento do modelo. Isso significa que as GANs podem ser utilizadas para inspirar novos *assets*, criar novas imagens e serem aplicadas diretamente nos jogos digitais.

**Palavras-chave:** Inteligência artificial, jogos digitais, arte.

## ABSTRACT

The interaction between artificial intelligence (AI) and art has emerged as a promising field within the contemporary creative process. In this article, we explored how the generative adversarial networks (GAN) model could assist in the creation of two-dimensional (2D) assets for digital game artists. To achieve this aim, we conducted a review of the literature and a case study with 2D assets from the *Axie Infinity* game. Through the research, it was discovered that the model synthesized new images that aligned with the characteristics and features similar to the dataset used in the model's training. This suggests that GANs can be employed to inspire new assets, produce novel images, and be directly integrated into digital games.

**Keywords:** Artificial intelligence, digital games, art.

## RESUMEN

La interacción entre la inteligencia artificial (IA) y el arte se ha mostrado como un campo prometedor en el contexto del proceso creativo contemporáneo. En este artículo, exploramos cómo el modelo de redes generativas adversarias (GAN) podría contribuir en la construcción de *assets* en dos dimensiones (2D) para artistas de juegos digitales. Para alcanzar este objetivo, se realizó una revisión de la literatura y un estudio de caso con *assets* 2D del juego *Axie Infinity*. A través de la investigación, descubrimos que el modelo sintetizaba nuevas imágenes que coincidían con las características y rasgos similares al conjunto de datos utilizado en el entrenamiento del modelo. Esto indica que las GANs pueden ser usadas para inspirar nuevos *assets*, crear nuevas imágenes y ser aplicadas directamente en juegos digitales.

**Palabras Clave:** Inteligencia artificial, juegos digitales, arte.

## 1. INTRODUÇÃO

Nos últimos anos, a indústria de jogos eletrônicos registrou uma movimentação financeira de 175,8 bilhões de dólares (RHYS et al., 2022). Conforme destacado por Bulhões (2022), houve um crescimento acelerado desse mercado durante a pandemia do SARS-CoV-2. O isolamento social, a variedade crescente de jogos eletrônicos, a disseminação dos dispositivos móveis e a excepcional qualidade na produção dos jogos, conduziu a um aumento significativo na busca por formas de entretenimento virtual e a um aumento no mercado dos jogos.

No mundo e no Brasil, estima-se que o mercado de jogos continuará crescendo nos próximos anos, ultrapassando 307 bilhões de dólares até o final de 2027 (PACETE, 2022; CRISTOFFERSON et al., 2022). Esse fenômeno ocorrerá devido ao seguinte conjunto de variáveis: a evolução das tecnologias, a adesão ao entretenimento digital, o aumento da popularidade dos jogos online, bem como a atração que o mercado de jogos traz a novos investidores e empresas que desejam lucrar com o segmento (IBIDEM, 2022). Atualmente, a evolução desse quadro culmina na expansão do mercado de jogos digitais e consequentemente no surgimento de novas empresas.

Impulsionadas pelo atrativo cenário econômico, as novas empresas do setor têm intensificado a produção de jogos, mirando o lucrativo potencial do mercado. Em sintonia com a expansão da indústria e com uma base de jogadores cada vez mais diversificada, elas estão refinando suas ofertas para atender nichos específicos de mercado (IBIDEM, 2022). Esta dinâmica tem alimentado um voraz apetite por talentos artísticos e recursos visuais, como os *assets* visuais, inclusive na academia brasileira (LIMA, 2023).

Os *assets* visuais são elementos artísticos que compõem a estrutura estética para o jogador compreender a história, a ambientação e a narrativa de um jogo. Eles são elementos produtores de sentido no jogo e são criados por artistas especializados na criação de arte para jogos digitais. Personagens, cenários, objetos e efeitos visuais são exemplos de *assets* visuais, que podem ser em duas dimensões (2D) ou em três dimensões (3D) e são fundamentais para criar uma experiência imersiva e atrativa para os jogadores.

A demanda por *assets* visuais em 2D e 3D está em constante expansão, impulsionada principalmente pelo desenvolvimento de jogos cada vez mais sofisticados e diferentes. À medida que as empresas investem em tecnologia de ponta e buscam oferecer experiências mais imersivas aos jogadores, a necessidade de recursos visuais também aumenta. Nesse contexto, sistemas que venham impulsionar a criação de *assets* visuais desempenham um papel fundamental.

Sistemas como, por exemplo, as Redes Adversárias Generativas (GAN) que são arquiteturas digitais que compõem um modelo de inteligência artificial. Um modelo que tem a capacidade de criar

imagens a partir de um banco de dados que pode ser construído por imagens de diferentes gêneros. Isto possibilita aos artistas criarem conteúdos/imagens para serem utilizadas em diversos fins (MÁTARAS, 2017; TIERNAN, 2022; TOLCHEVA, 2022).

Nessa perspectiva, o artigo investiga como o modelo de GANs pode contribuir na construção de *assets* 2D para artistas de jogos digitais. Para atingi-lo foi realizada uma revisão da literatura e um estudo de caso com *assets* 2D do jogo *Axie Infinity*.

O *Axie Infinity* é um jogo online bidimensional que apresenta *assets* distintos para coleção e venda. Ele foi criado pela *Sky Mavis* em 2018, como um gênero de estratégia e RPG (*Role-Playing Game*), onde os jogadores coletam, criam, e batalham com criaturas conhecidas como *Axies*. Essas criaturas são *assets* 2D implementadas com *Non-Fungible Tokens* (NFTs), um registro distribuído que garante a imutabilidade e a segurança das informações registradas, assim tornando cada *Axie* único para colecionadores e jogadores.

Nesses contextos optou-se pelo *Axie Infinity* devido ao seu caráter artístico singular. Cada componente gráfico do jogo é exclusivo, carregando significado simbólico, sem qualquer duplicação. Outro fator decisivo para sua escolha é que este jogo possui mais de 1.000 *assets* que podem ser utilizados no treinamento do modelo adotado em nossa investigação.

O trabalho está estruturado em quatro partes. Na primeira, foi feita uma introdução ao tema. Na parte dois está a metodologia. Na terceira, discutem-se os temas que embasaram a pesquisa (seções 3 e 4) e é apresentada a análise da arquitetura do modelo de GANs, juntamente com o estudo de caso (seção 5). Na quarta, são expostos os resultados, acompanhados das inferências baseadas nas observações (seções 6 e 7).

## 2. METODOLOGIA

Este estudo adota uma abordagem indutiva, onde se observa inicialmente o fenômeno real em suas conexões e, em seguida, se desenvolvem suposições que auxiliam na resolução do questionamento proposto (DRESCH et al., 2020; GIL, 2022). Nessa perspectiva, optou-se pelo método científico indutivo devido à sua capacidade de permitir a realizações de inferências sobre o objeto de pesquisa e responder ao problema em questão. Ademais, foram empregados também os métodos estudo de caso e observação direta, os quais possibilitaram uma compreensão mais profunda e detalhada do fenômeno investigado, enriquecendo a análise com observações específicas e contextualizadas do objeto de estudo (DRESCH et al., 2020; GIL, 2022).

A associação de ambos os métodos citados 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). Nesse contexto, a metodologia é composta de uma sequência lógica de etapas que foram incorporadas à pesquisa em uma instância de pré-pesquisa e pós-pesquisa para validar a hipótese de que o modelo de redes adversárias generativas tem o potencial de automatizar a criação de *assets* 2D para artistas de jogos.

A primeira etapa foi a observação do fenômeno de interesse em uma estrutura macro (DRESCH et al., 2020) que neste estudo é o potencial do modelo conceitual de redes adversárias generativas na construção de *assets* 2D para artistas de *games*. Em seguida foram observados os alicerces que fornecem suporte ao tema em uma estrutura micro. Dessa forma, foi observada a estrutura conceitual da arte digital dos *games*, assim como a arquitetura das redes adversárias generativas que possibilitam a criação e discriminação de imagens em sua estrutura.

Na segunda etapa foi realizada uma consulta a literatura existente acerca do tema e a demarcação dos limites da investigação (DRESCH et al., 2020; GIL, 2022). Assim, foram consultadas referências bibliográficas que nortearam a pesquisa: Salgado (2020), Goodfellow et al, (2014), Salgado (2020), Duarte (2012), Lieser (2009), Russell e Norving (1995) dentre outros que podem ser encontrados ao longo do texto.

Na terceira etapa foi realizado o planejamento do estudo de caso (DRESCH et al., 2020). Nela foi definido o modelo conceitual das redes (o modelo escolhido foi o de Goodfellow et al. (2014) na linguagem de programação Python) e os *assets* visuais que seriam usufruídos no banco de dados. Os *assets* visuais que foram escolhidos para compor o banco de dados consistem em personagens do *game Axie Infinity*. Esses recursos foram obtidos a partir da seção pública do jogo com finalidades educacionais e de pesquisa, totalizando 15.000 *assets* visuais em 2D. O modelo demanda mais de 1.000 *assets* para produção de novos. A coleta foi realizada de duas formas. Num primeiro momento de forma manual e em um segundo por meio do uso de código em *Node.js* que é um *framework* para a utilização de linguagem *JavaScript*. Essas imagens eram coloridas e foram redimensionadas para serem usadas nos testes do modelo conceitual de redes adversárias generativas, nas dimensões de 32 x 32 pixels.

Na quarta etapa da pesquisa foi realizada a condução do teste (DRESCH et al., 2020). Os ativos visuais utilizados no treinamento deram um total de 15.000 *assets* coloridos, e tinham dimensões de 32 x 32 pixels. O algoritmo de otimização utilizado foi o *Sigmoide*, o tamanho do lote (*batch*) utilizado foi de 100. Para o teste, foram usadas duas camadas de redes convolucionais, ambas com 64 filtros. O tempo de geração dos *assets* foi de 4 horas e foram utilizadas um total de aproximação

de 300 épocas. Dentro desse contexto, o planejamento observacional dos resultados foi pensado para observar os parâmetros de pigmentação (cor) e formato. Estes critérios foram escolhidos devido a significância que eles possuem na criação de *assets* visuais.

### 3. ARTE DIGITAL

A arte digital é um termo que engloba todas as manifestações artísticas que envolvem o uso da tecnologia digital. Ela é um *modus operandi* que engloba as artes que utilizam a linguagem digital em sua produção, distribuição e recepção (SALGADO, 2020). A arte digital pode ser vista como um entrelugar que combina em grande medida a arte, a ciência e as tecnologias digitais para formar as manifestações artísticas.

A raiz da arte digital concatena três ciências em grande medida. 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, as tecnologias digitais que detêm um conjunto de técnicas, habilidades, métodos e processos para produção de artefatos digitais ou híbridos. Desse modo, a arte digital concatena arte, ciência e tecnologias digitais para produzir um novo tipo de manifestação que lhe é própria. Uma manifestação particular que está situada entre as características do meio digital e uma linguagem por vezes visual (LIESER, 2009). Essa manifestação utiliza recursos tecnológicos digitais para alcançar o desfecho que não seria alcançável por outros meios.

A produção da arte digital é feita com diferentes recursos tecnológicos. Nela, os artistas experimentam conceitos com inúmeras engenharias para depurar, conhecer, parametrizar e expor sua produção. Tal fenômeno ocorre devido às tecnologias proporcionarem diversas modalidades, tanto do ponto de vista da produção, quanto da recepção da obra de arte (SALGADO, 2020).

A obra de arte digital pode ser produzida utilizando recursos digitais ou físicos. Ela pode ser criada com a utilização de software (tais como *Adobe Illustrator*, *Adobe Photoshop*, *Gimp*, *Corel Draw* etc.), de algoritmos e de hardware (tais como *tablets*, *drones*, *smartphones*, *smart rings*, *desktops*, *laptops*, câmeras digitais etc.). As diferentes formas da arte digital estão ligadas ao meio de produção, os quais são elementos chaves na criação dos modelos artísticos. Eles possibilitam aos artistas expandirem e criarem conceitos. Um exemplo é o conceito de arte robótica.

A arte robótica é uma manifestação artística em que são utilizadas máquinas que podem se movimentar e agir para produzir arte. Neste campo, os artistas usam a robótica como uma ferramenta para desenvolver tanto performances quanto peças. Eles exploram a modelagem de comportamento mecânico e tornam possíveis situações interativas em espaços físicos ou telemáticos.



Outro conceito imerso na arte digital é a arte generativa, que é uma manifestação que produz arte de forma autônoma. Ela é uma prática na qual o artista cria um processo, um conjunto de regras, numa linguagem de programação ou em um programa de computador, ou outro mecanismo, que então é colocado em movimento com algum grau de autonomia, contribuindo ou resultando em um trabalho de arte completo (GALANTER, 2003). Ademais, a arte generativa pode ser produzida de duas formas.

Na primeira forma de produção da arte generativa, o artista não propõe limites criativos. Nela, os parâmetros não possuem fronteiras rígidas de possibilidades e formas. A criação ocorre de forma fluida e randômica, por meio de algoritmos que criam composições sem uniformidade ou quadros fixos. Como exemplo, podemos citar a arte generativa do artista Pedro Paulo Vecchietti (Imagem 1).

**Imagem 1** – Arte generativa de Pedro Paulo Vecchietti



**Fonte:** Peña- Bickley, 2021

Essa obra é abstrata e sem uma simetria ou limite concreto de uma forma estaticamente congelada. Nela, há uma mistura de cores que compõem a imagem. Ela não possui uma forma animal, humanoide ou de algum objeto criado pelo ser humano. Nesse contexto, a criação de Vecchietti não possui padrões fixos, ela é fluida e abstrata.

Na segunda forma de produção da arte generativa, o artista impõe limites semirrígidos ou rígidos no software ou código que utiliza para a criação. Ele propõe limites do que se espera como resultado, diferentemente do que ocorre com a primeira forma de produção. Desse modo, caso haja diferentes formas de cilindro, círculos, representações humanoides e objetos, ele propõe os parâmetros dos resultados de forma rígida ou semirrígida, possibilitando uma criação parcialmente aleatória. Como exemplo, é possível citar o trabalho do artista Manolo Gamboa Naon (Imagem 2).

**Imagem 2** – Arte generativa de Manolo Gamboa Naon



**Fonte:** Naon (2022)

Na obra de Naon é possível visualizar estruturas com formas rígidas compostas por um conjunto de formas geométricas que se repetem consecutivamente. A repetição dos losangos, em diferentes padrões de cores, forma uma estrutura que está dentro das dimensões e limites preestabelecidos pelos parâmetros que o artista definiu durante o processo de codificação.

Os modelos de arte regenerativa e robótica estão imersos no entrelugar da arte digital. Conforme Salgado (2020, p. 30) quando nos referimos a arte digital, pode parecer que delimitamos fronteiras rígidas, mas a arte digital é um campo de “experimentação por excelência, pois, por um lado, o universo da tecnologia é amplo e evolui em alta velocidade, permitindo novas possibilidades; e, por outro, cada vez mais o domínio total da tecnologia foge aos artistas, dada a sua pluralidade”. O que culmina num contínuo aprendizado de ferramentas que refletem o tempo do artista, como “o computador que se tornou um instrumento que transformou a nossa sociedade e a cultura como nenhum outro o fez nas últimas décadas” (LIESER, 2009, p. 6), assim possibilitando aos artistas criarem conceitos, paradigmas e construir novas manifestações a partir de outras obras e de sua própria criatividade (ARANTES, 2005).

Nessa perspectiva, a arte digital não é uma manifestação monolítica e congelada no espaço. Ela acontece em um *continuum* no qual os paradigmas sobrepõem-se, hibridizam-se, contaminam-se e criam espaços, subespaços e conceitos dentro de uma estrutura macro. Uma estrutura que abrange diversos fenômenos artísticos que são nomeados dentro do corpo macro da arte digital. Como exemplo, é possível mencionar a arte Fractal, modelagem 3D, desenho vetorial, ilustração digital, pintura digital, *pixel art*, *software art*, *net.art*, *generative art*, bem como, a *game art* (ou sinonimamente arte de *games*) e diversas outras manifestações e composições que utilizam a linguagem digital em sua produção, distribuição e recepção.



#### 4. JOGOS E PRODUÇÃO DE ARTE

Desde o seu surgimento, em 1959, os jogos eletrônicos vêm se consolidando como uma nova mídia e ganhando espaço na cultura popular por sua natureza multimidiática, artística e interativa. Eles, ao longo do tempo, saíram de um estado de brinquedo para mídia e manifestação artística em todo o mundo (HUIZINGA, 2020; LUZ, 2021). Esse acontecimento os consolidou como um fenômeno sociocultural de grandes proporções (WILLIAMS, 2017; HUIZINGA, 2020).

Trata-se de um fenômeno que é estudado por diferentes correntes teóricas e campos científicos (Comunicação, Computação, Ciências da Educação, Economia, Administração e Artes) e que ocorre devido a sua habilidade de expressão de sentidos e significados para os interagentes de qualquer idade, assim como as fases de sua evolução estrutural, conceitual e artística ao longo da história humana.

A produção artística para jogos ao longo dos anos passou por transformações significativas, refletindo não apenas os avanços tecnológicos, mas também os próprios paradigmas culturais e estéticos que moldaram cada época. Nos primórdios da produção artística para jogos, a arte era limitada pelas capacidades tecnológicas do período. O visual era simplista, muitas vezes representado por formas geométricas básicas e uma paleta de cores limitada (KENT, 2001). No entanto, mesmo com essas restrições, os primeiros artistas de jogos conseguiram transmitir a essência do jogo, comunicar seus fenômenos e criar uma experiência para os jogadores.

Conforme a tecnologia eletrônica/digital avançou, os consoles e computadores se tornaram mais potentes, permitindo uma maior complexidade gráfica (LUZ, 2021). A arte dos jogos começou a adotar detalhes mais intrincados, texturas mais realistas e animações fluidas. Isso culminou no cenário atual onde temos jogos que são praticamente indistinguíveis da realidade, com mundos virtuais abertos, personagens com detalhes minuciosos e ambientes verossímeis.

Dentro do universo dos jogos, a produção artística apresenta variações consideráveis, moldadas tanto pelo tipo de jogo, quanto pela dinâmica da equipe de desenvolvimento. Essa diversidade muitas vezes se traduz em uma demanda por *assets* que podem oscilar entre contínua e sazonal. Na demanda contínua, os artistas são impulsionados a gerar conteúdo regularmente para atualizações frequentes. Por outro lado, a demanda sazonal envolve a criação de arte para ocasiões específicas, como eventos, celebrações ou elementos narrativos que enriquecem a trama do jogo. Cada *asset*, nesse contexto, não apenas embeleza, mas também narra e contextualiza a ação em tela, conferindo profundidade e significado à experiência do jogador.

Os *assets* são elementos artísticos que compõem os games. Eles podem ser de diferentes naturezas como sonoros, mecânicos e visuais e são criados por artistas digitais que utilizam softwares

especializados para produzir elementos gráficos, sonoros e mecânicos de alta qualidade. Os softwares mais comuns incluem o *Adobe Photoshop*, *Illustrator* e *After Effects* (para gráficos e animações), o *Ableton Live* e *FL Studio* (para a produção de música e áudio), o *Unity* e *Unreal Engine* (para o desenvolvimento de jogos).

A criação desses *assets* é parte crucial do processo de desenvolvimento de *games* e é essencial para criar uma experiência imersiva e envolvente para o jogador. Por isso, cada tipo de *asset* é discriminado e trabalhado separadamente, para assim garantir a qualidade e efetividade em sua função dentro do jogo.

Os *assets* sonoros, por exemplo, incluem efeitos de sons que os games possuem. São sons de passos, de ambiente, magias, itens e diálogos dos personagens (NGUYEN, 2021). Eles são os sons que compõem o jogo. Os *assets* sonoros são criados em softwares especializados em produção de áudio, como o *Adobe Audition*, *Kristal Audio Engine*, *Ableton Live* e o *FL Studio*. Após finalizados são exportados para formatos de arquivo como WAV e MP3.

Os *assets* mecânicos são um conjunto de autômatos utilizáveis. Eles envolvem a programação e o desenvolvimento de sistemas e mecânicas de jogo, a jogabilidade, a física do jogo e as animações (ROGERS, 2013; NGUYEN, 2021). Eles são criados em *softwares* de programação como o *Unity* e o *Unreal Engine*, e exportados para formatos de arquivo como Java Script, C# e C++ ou usados diretamente nos jogos.

Os *assets* visuais são itens, elementos dos cenários e até personagens. Eles podem ser de dois tipos: duas dimensões (2D) ou três dimensões (3D). Os *assets* em duas dimensões são planos e vistos de um ângulo da câmera nos jogos (NGUYEN, 2021). Eles podem ser personagens, cenários e itens utilizados (ROGERS, 2013). Eles são imagens que vão compor o game e são criados em softwares como *Adobe Photoshop*, *CorelDRAW*, *Illustrator* e *Gimp*. A sua criação pode ocorrer em bitmap ou em formato de imagem vetorial, mas são comumente exportados para uso em formatos de arquivo PNG, JPEG, TIFF, GIF e BMP que são formatos de imagem em bitmaps. Os *assets* em três dimensões são elementos artísticos que ocupam um espaço tridimensional. São personagens, itens, roupas e ambientação que possuem um relevo e textura. Eles são criados em softwares de modelagem 3D como o *Blender*, *Maya*, *3Ds Max*, *ZBrush*, *Cinema 4D* e são exportados para uso em formato de arquivos MAX, 3DS, OBJ, DAE e FBX que é um formato universal que permite a transferência de modelos 3D, texturas, animações e outras informações entre diferentes softwares e plataformas de desenvolvimento de jogos.

Os bitmaps são matrizes bidimensionais e espaciais compostas de *pixels* que são o menor elemento de resolução da imagem representados por bits (WILLRICH, 2000; HAVALDAR &

MEDIONI, 2010). Os bits, nos *assets*, são elementos estruturantes que possuem a função de representar os valores de tons e cores que compõem a imagem (WILLRICH, 2000). Nesse contexto, os *assets* em 2D também podem ser compreendidos como matrizes numéricas compostas de bits e seus múltiplos. Uma matriz é utilizada em jogos para explorar/criar ambientações, elementos artísticos, interfaces e narrativas que gerem experiências para o usuário. Esta matriz, complexa e rica em detalhes, oferece um vasto campo de possibilidades para a Inteligência Artificial (IA). Atualmente, com o avanço da tecnologia e o crescente desenvolvimento de algoritmos sofisticados, IAs estão sendo cada vez mais integradas à indústria dos games. O potencial de utilizar IA para analisar e aprender com essa matriz, para em seguida criar novos elementos, é vasto e cada vez maior.

## 5. INTELIGÊNCIA ARTIFICIAL

A Inteligência Artificial (IA) é um campo do conhecimento que examina as faculdades das arquiteturas digitais para simular o comportamento humano. Ou seja, o comportamento inteligente de tomada de decisões, da distinção de objetos e da criação de conceitos, conteúdos e imagens. Ela empenha-se na realização de tarefas específicas, como demonstração de teoremas matemáticos, diagnóstico de doenças, controle de jogos e criação de poemas (JO, 2021; THOMPSON, 2021; SHAHRIAR, 2021). Em outros termos, ela busca solucionar problemas por meio de um agente inteligente formado por uma sequência de instruções em código de programação (RUMELHART & MCCLELLAND, 1986; BITTENCOURT, 1998).

O agente inteligente pode ser do tipo forte ou fraco. O agente fraco ou modelo de inteligência fraca é o que encontramos no dia a dia. Esse modelo recebe uma entrada de dados, realiza um processamento e resulta em uma saída. Em outros termos, ele possui uma função determinada e a executa conforme o programado, sem ser capaz de desenvolver uma consciência ou uma compreensão do que o cerca (HAMMOND, 2015). O agente forte ou modelo de inteligência artificial forte pode ser comparado com o que é apresentado no cinema de ficção científica (LEMOS, 2022). Eles são capazes de recriar as funções humanas em seus sistemas sintéticos (funções de raciocínio emocional, lógico e uma consciência acerca do que o circunda). Todavia, o modelo forte ainda não existe, ele é apenas um conceito filosófico (HAMMOND, 2015; MUELLER & MASSARON, 2021; LEMOS, 2022).

O modelo fraco possui técnicas (sistemas de recomendação, sistemas especialistas, de reconhecimento de imagens, reconhecimento de linguagens naturais etc.) que desempenham diversas atividades no cotidiano das pessoas. As técnicas que atualmente ganham destaque são aquelas baseadas em aprendizado de máquina, aprendizado profundo e redes neurais artificiais (estas redes

neurais são a base de nossa investigação. Por isso as redes adversárias generativas serão superficialmente tratadas neste artigo).

O modelo conhecido como "fraco" emprega diversas técnicas - como sistemas de recomendação, sistemas especialistas, reconhecimento de imagens e de linguagem natural - que influenciam significativamente o cotidiano das pessoas. Atualmente, as abordagens que se destacam nesse modelo são as que envolvem aprendizado de máquina, aprendizado profundo (*deep learning*) e redes neurais artificiais. Estas últimas, em particular, são o foco principal de nossa pesquisa por conterem o modelo de redes adversárias generativas.


### 5.1 REDES NEURAIS ARTIFICIAIS

A Rede Neural Artificial (RNA) é um modelo de inteligência artificial. Um modelo desenvolvido com base nas redes neurais biológicas que constituem o cérebro humano (CACCIA, 2018; GRANDO, 2022). Um modelo que foi criado com o intuito de oferecer ao usuário uma máquina que aprenda de forma inspirada no cérebro humano (PHILLIPS, 2020; GRANDO, 2022).

O modelo aprende com base em um conjunto de dados que contém experiências em uma estrutura complexa. Essa estrutura pode ser compreendida como um sistema nervoso artificial. Esse sistema é composto de camadas de neurônios artificiais que podem se conectar para produzir um determinado resultado. Os neurônios artificiais são a menor unidade operante no sistema e graças a eles diferentes estruturas foram criadas ao longo dos tempos. Um exemplo desses neurônios é o *perceptron*.

O *perceptron* pode ser analogamente comparado a uma célula do sistema nervoso. Ele é um modelo de neurônio que funciona através de uma série de etapas (Imagem 3).

**Imagem 3** – Estrutura de um neurônio e do *perceptron*



Neurônio

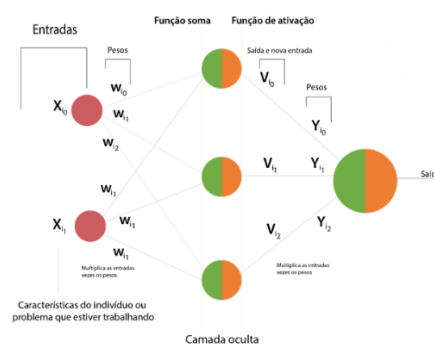
PERCEPTRON

Fonte: Produzido pelo autor

Nele há uma entrada (dendritos) e saída (axônios) que fazem a troca de informações, bem como uma função que ativa a estrutura. O seu objetivo é atuar como um classificador ou gerador de funções lógicas binárias. Ele foi implementado em meados da década de 50. Na época, Frank Rosenblatt desenvolveu o teorema da convergência do *perceptron* que determina que o algoritmo de aprendizagem pode ajustar os pesos de conexão para corresponderem a quaisquer dados de entrada, desde que exista tal correspondência (RUSSELL & NORVIG, 2013). Ele serviu para avançar diversas aplicações e teorias da época. O *perceptron* funciona por meio de processo de entrada, processamento e processo de saída. Nele as entradas são multiplicadas pelos pesos e somadas na função soma. Em seguida, esses valores são utilizados como parâmetros para a *Step function* que é a função degrau ou de ativação que irá passar o valor de saída (BERGER, 2016).

O *perceptron* como um neurônio funciona também como uma IA simples. Todavia, em problemas mais complexos, um *perceptron* é ineficiente, sendo necessária a junção de vários *perceptrons* para resolução dos problemas. Essa junção é chamada de *perceptron* de multicamada (Imagem 4).

**Imagem 4** – Perceptron multicamadas



**Fonte:** Produzido pelo autor

O *perceptron* de multicamadas, também chamado de *multilayer perceptron*, é uma arquitetura mais poderosa do que o *perceptron* de uma camada. Ele pode resolver problemas mais complexos, os quais não possuem uma resposta binária. Outro ponto importante é que ele resolve problemas não linearmente separáveis

O poder da *multilayer perceptron* está associado à quantidade de camadas ocultas que possui, mas é importante ressaltar que nem sempre mais camadas significa melhor desempenho. Embora a arquitetura seja capaz de resolver problemas não lineares com complexidade maior, é preciso cuidado ao escolher a quantidade de camadas, pois uma rede grande demais pode comprometer o desempenho da arquitetura na função que exerce.

O aprendizado das RNAs é dividido em três paradigmas: o aprendizado não supervisionado, o aprendizado supervisionado e o aprendizado por reforço. Essa divisão emerge da estrutura do treinamento que define o modo como a RNA guardará os exemplos para produzir um novo conhecimento na saída de dados.

O aprendizado não supervisionado é um aprendizado não rotulado em que o processo não possui uma supervisão humana. 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 por reforço é um tipo de aprendizado em que o agente inteligente aprende por meio da atualização de parâmetros para maximização de recompensa e para minimizar a penalidade no exercício de uma função (JO, 2021). Essas formas de aprendizagem são utilizadas em modelos de RNAs, como por exemplo o modelo de Redes Adversárias Generativas.

## 5.2 REDES ADVERSÁRIAS GENERATIVAS

Criado por Goodfellow et al. em 2014, o modelo adversarial generativo (GAN) é um modelo arquitetural de redes neurais profundas, compostas por um conjunto de camadas convolucionais. Estas camadas são capazes de extrair características das imagens de entrada, realizar processamento e, posteriormente, gerar uma nova imagem. Sua estrutura funciona por meio de dois agentes convolucionais: um gerador e um discriminador, que competem entre si. O gerador tem a função de criar imagens novas, enquanto o discriminador avalia essas imagens, tentando distinguir entre as imagens geradas artificialmente e imagens reais para gerar um resultado.

A arquitetura do modelo GAN conforme Goodfellow et al (2014) funciona a partir da entrada de um ruído  $z$ , obtido por uma distribuição normal ou uniforme, que é utilizado em um gerador  $G$  para criar uma imagem  $x$ , onde  $x = G(z)$  (GOODFELLOW et al, 2014). Após isso, o discriminador  $D$  analisa tanto as imagens reais quanto as imagens geradas pelo gerador e determina a probabilidade de cada imagem ser real. Em seguida, a retropropagação de erros é usada para ajustar os pesos das redes do gerador e do discriminador. Nesse contexto, para realizar seu objetivo, calcula-se a função de custo utilizando entropia cruzada, obtendo a seguinte equação:

$$\frac{\max}{D} V(D) = E_{z \sim P_{data}(x)} [\text{Log} D(x)] + E_{z \sim P_Z(z)} [\text{Log} (1 - D(G(z)))] \quad (1)$$

reconhece imagens reais melhor      reconhece imagens gerados melhor

Nesse sentido, o objetivo para o gerador é criar imagens com o maior valor possível para “enganar”  $D$ . Dessa forma usa-se a seguinte equação:



$$\frac{\min}{G} V(G) E_{z \sim P_z(z)} \left[ \text{Log} \left( 1 - D(G(z)) \right) \right] \quad (2)$$

otimiza G para enganar o discriminador

Nesse contexto, pode-se dizer que GANs são um jogo minimax onde G quer minimizar V enquanto D quer maximizá-lo (GOODFELLOW et al, 2014; MENDONÇA, 2019) como pode ser visto na seguinte equação:

$$\frac{\min}{G} \frac{\max}{D} V(D, G) = E_{x \sim P_{data}(x)} [\text{Log} D(x)] + E_{z \sim P_z(z)} \left[ \text{Log} \left( 1 - D(G(z)) \right) \right] \quad (3)$$

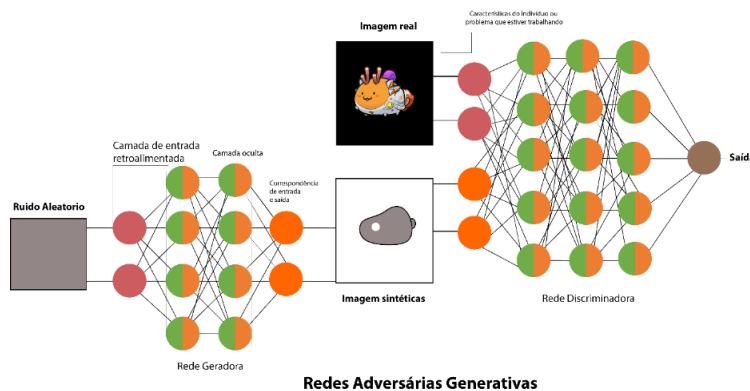
Desse modo, ambas as redes estão em um processo de otimização contínuo por meio das equações 1, 2 e 3. A rede generativa vai aprendendo a criar imagens semelhantes aos reais e a discriminadora os separa.

Dentro dessa perspectiva, durante o treinamento, o gerador é treinado para enganar o discriminador, ou seja, produzir saídas que são difíceis de serem diferenciadas dos dados reais pelo discriminador. Enquanto isso, o discriminador é treinado para distinguir entre as saídas geradas pelo gerador e os dados reais.

A competição é implementada por meio de uma função de perda que o modelo tenta minimizar. A função é composta por duas partes: uma parte que penaliza o gerador por produzir saídas que o discriminador pode facilmente identificar como falsas e a outra parte que penaliza o discriminador por falhar em distinguir as saídas produzidas pelo gerador dos dados reais.

Ao longo do treinamento, o gerador aprende a produzir saídas mais realistas, enquanto o discriminador aprende a distinguir melhor entre as saídas produzidas pelo gerador e os dados reais. Quando o treinamento termina, espera-se que o gerador produza saídas que são indistinguíveis dos dados reais, e o discriminador não possa mais distinguir entre as saídas geradas e os dados reais. Dessa forma, a escolha dos dados é de suma importância. A Imagem 5 apresenta a arquitetura da GAN.

**Imagem 5** – Diagrama da arquitetura da GAN



**Fonte:** Produzida pelo autor

A rede geradora exerce a criação de imagem por meio de um banco de dados composto de ruídos. Esses ruídos são imagens aleatórias que podem ser compreendidas como matrizes numéricas que são utilizadas para gerar as primeiras imagens que serão enviadas para a rede discriminadora. Desse modo, a rede geradora vai criando imagens sintéticas a partir de um banco de dados e as envia para a rede discriminadora (KUNTAL, 2017).

A rede discriminadora tem como objetivo distinguir e reconhecer as imagens produzidas pela rede geradora, identificando suas características. Essa distinção é realizada com base nos dados disponíveis, permitindo que os resultados sejam utilizados no processo de *backpropagation* que ajusta os pesos da rede para melhorar a qualidade das imagens (KUNTAL, 2017).

Esse fenômeno se repete até a rede geradora conseguir criar imagens esteticamente semelhantes ao conjunto de imagens reais. Nesse ponto, a rede começa a criar diversas imagens diversificadas através da manipulação do espaço latente (espaço multidimensional que representa a variabilidade dos dados de entrada e que é mapeado para o espaço de saída pela rede geradora). Ao manipular esse espaço, a rede pode criar imagens com características específicas tais como mudanças na pose, na iluminação, nas texturas etc.

Essa capacidade de criar imagens diversificadas tem inúmeras aplicações práticas, como a geração de novos produtos em *design*, na criação de personagens em jogos e animações, na produção de arte digital entre outras.

### 5.3 GANS NA CRIAÇÃO DE ASSETS PARA JOGOS DIGITAIS

Nesse contexto, buscamos explorar até que ponto a IA, especificamente as Generative Adversarial Networks (GANs), poderia auxiliar artistas na criação de novos *assets* para jogos. Para essa investigação, conduzimos um estudo de caso com *assets* de personagens do jogo *Axie Infinity* coletado do espaço público para fins educacionais (Imagem 6).

### Imagem 6 – *Assets* visuais em 2D do *Axie Infinity*

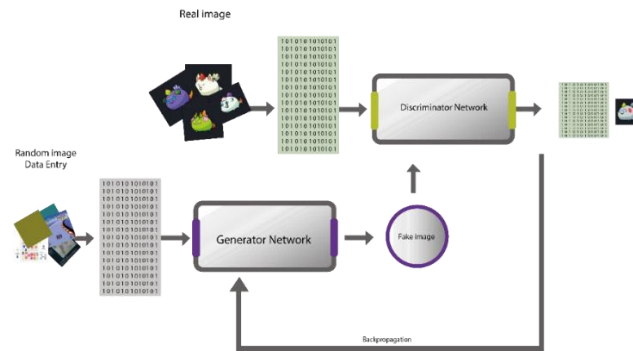


**Fonte:** Produzida pelo autor

Esses *assets* são modelos de personagens utilizados em *Axie Infinity* que foram utilizados como parâmetros reais para treinar a rede discriminadora. O objetivo era entender se o modelo GANs poderia criar novos personagens para artistas, colaborando assim no processo de desenvolvimento artístico de games. Para compreender a capacidade das GANs, o modelo foi treinado utilizando um conjunto de dados composto por 15.000 imagens de personagens do jogo, bem como, um conjunto de imagens aleatórias (ruídos) cada uma com dimensões de 32 x 32 pixels. Este treinamento utilizou o algoritmo adversarial das GANs e durou um período de 5 semanas. Esse tempo de treinamento se deveu à grande quantidade de imagens fornecidas, ao tamanho do batch estabelecido em 100 e ao total de aproximadamente 300 épocas de treinamento.

No processo de criação dos personagens do jogo *Axie Infinity*, a rede geradora utiliza um banco de dados composto por imagens aleatórias que são representadas como matrizes numéricas para produzir as primeiras imagens enviadas para a rede discriminadora. Essas imagens sintéticas são criadas com o objetivo de enganar a rede discriminadora. A rede discriminadora, por sua vez, analisa as semelhanças nas imagens geradas com base nas imagens reais de *assets* que ela possui em seu banco de dados. Quando identificadas as semelhanças, a rede discriminadora pode realizar o *backpropagation* para a rede geradora se ajustar e criar imagens. (KWAK e KO, 2020) Esse processo para a criação de personagens únicos e diversificados pode ser visto na Imagem 7 onde é apresentada a estrutura de funcionamento do modelo.

### Imagem 7 – Representação Gráfica do Processo de Criação de Personagens



Fonte: Produzida pelo autor

É possível visualizar de forma ilustrativa um conjunto de ativos artísticos do *game Axie Infinity* na condição de imagens reais a serem utilizadas pela rede discriminadora. E outro conjunto de imagens aleatórias que são utilizadas da rede geradora na condução de ruídos.

No processo, a rede geradora cria imagens falsas e as envia para a rede discriminadora. Essas imagens enviadas pela rede na primeira época são diferentes das imagens reais. E essa diferença faz a rede discriminadora tomar uma decisão.

A rede discriminadora ao receber as imagens realiza uma comparação. Nesse ato é comparado os parâmetros das imagens recebidas com a do modelo real de *assets* do *game Axie Infinity*. Em seguida, ela retorna como saída um conjunto de dados envolvendo a distinção das imagens que são utilizadas no ajuste de pesos como o *backpropagation*. Logo após, a rede geradora volta a funcionar com novos ajustes. Esse novo funcionamento e início de círculo é denominado de época (a cada época, as imagens serão criadas de formas diversificadas). O fenômeno se repete até a rede geradora igualar esteticamente suas criações imagéticas aos dos modelos reais. Nesse ponto, a rede geradora começa a criar imagens que enganam a rede discriminadora com os resultados.

## 6. ANÁLISE DOS RESULTADOS

Os *assets* gerados pelo modelo são variados e diversos, isto é, apresentam diferentes formas, cores e características. Além disso, os resultados obtidos variaram em sua qualidade, já que alguns foram mais relevantes do que outros. Para exemplificar, observemos na Imagem 8 que contém diversos *assets* gerados pelo modelo, com diferentes formas e cores. Eles demonstram a variedade e a riqueza de *assets* gerados pelo processo de geração automatizada.

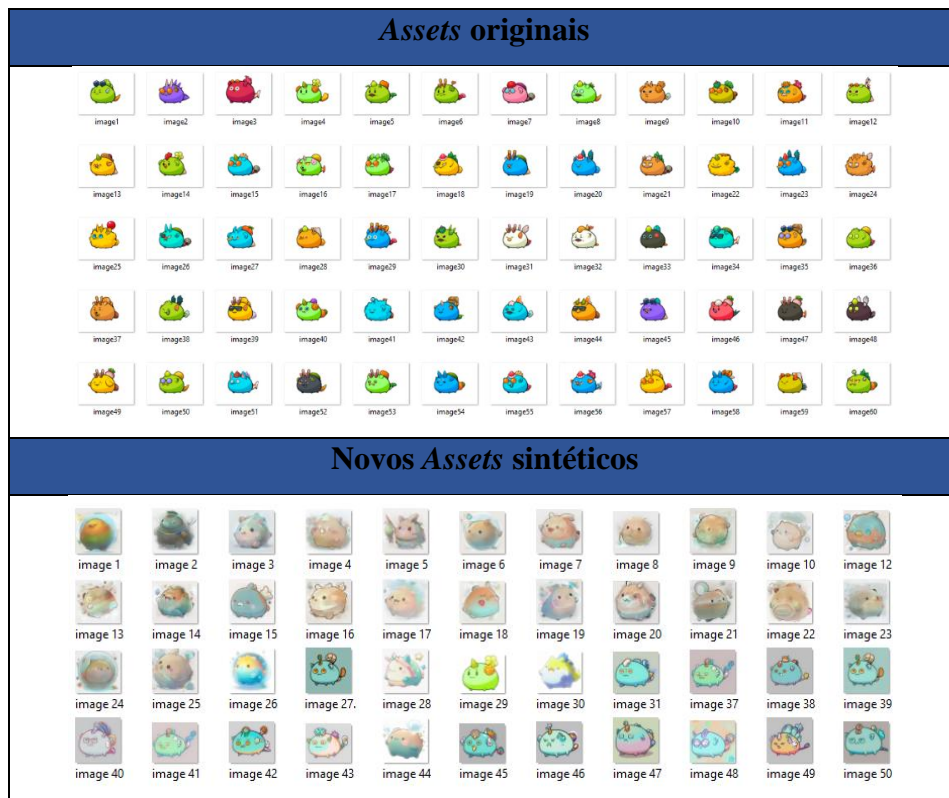
**Imagem 8 – Resultados variados**



**Fonte:** Produzida pelo autor

Esses *assets* foram criados pelo modelo, ou seja, eles são resultantes do treinamento realizado com personagens do *game*. Eles têm formatos e cores diferentes. Ademais, apresentam significância (estrutura do objeto estético) ao contexto. Uma estrutura que proporciona uma similitude visual entre as imagens que foram criadas de forma sintética pela GAN e as imagens originais criadas por humanos (Quadro 1).

**Quadro 1 – Os *assets* originais e *assets* sintéticos**



**Fonte:** produzido pelo autor

Ao comparar os novos *assets* criados pelo modelo com aqueles já existentes no jogo, é possível notar diferenças significativas nas formas, posições e detalhes dos elementos. As imagens produzidas

pelo modelo apresentaram novas combinações de cores e texturas, além de elementos visuais que antes não existiam no *game*

No Quadro 1 é possível perceber que o modelo de GANs criou novos *assets* com características exclusivas, tais como novos olhos, bocas, chapéus e rabos. Este modelo foi capaz de gerar *assets* que se diferenciam dos já existentes, trazendo possibilidades para a criação de novos personagens no *game*. Os elementos criados pelo modelo apresentam novas formas singulares. Tal singularidade apresenta-se de forma positiva, para os casos em que o personagem apresenta uma similitude, e negativa, para os casos que estão destoantes. Os casos destoantes são os que não possuem similitude, ou seja, eles são alongados ou curtos demais, e não uniformes. Os *assets* dessa forma produzem resultados ruins, já que eles não possuem uma similitude para serem usados diretamente no *game*. Todavia, eles podem ser usados para inspirar os artistas com suas texturas e combinações de cores e formas. Isto pode ser uma vantagem na criação de novos elementos visuais para o jogo.

Ao analisar os resultados obtidos, é possível verificar que o modelo de GANs apresenta capacidade para gerar novos *assets* visuais a partir dos dados existentes. Isto sugere que os artistas podem utilizar este modelo para produzir *assets*.

## 7. CONCLUSÃO

Neste artigo, explorou-se como o modelo de redes adversárias generativas (GAN) poderia contribuir na construção de *assets* em duas dimensões (2D) para artistas de jogos digitais. A investigação percorreu um caminho teórico, abordando conceitos chave relacionados à arte digital, produção de arte para jogos e Inteligência Artificial, incluindo as redes adversárias generativas. Adicionalmente, foram conduzidos um estudo de caso com *assets* para melhor compreender como o modelo poderia auxiliar artista de jogos.

A partir do estudo de caso foi possível perceber que o modelo tem a capacidade de criar imagens com traços semelhantes às usadas no treinamento. Esse fenômeno possibilita ao modelo criar novas imagens dentro de uma significância estética que se situa nas características e traços similares aos do grupo de amostra usado no treinamento. Também foi possível perceber que o modelo conceitual tem potencial para criar ativos de forma singular, com formatos e cores diferentes dos propostos nos dados originais. Essa característica possibilita ao artista a criação de ativos diversificados e únicos que podem ser utilizados para criar jogos mais personalizados ou inspirar novas produções. Isto abre novas possibilidades para a criação artística em *games*, permitindo que os artistas explorem novas formas de expressão e criatividade através da utilização de GANs.



Ademais, o emprego de GANs na criação de *assets* 2D tem potencial para redefinir a operacionalidade nas equipes de desenvolvimento de jogos. Com máquinas capazes de gerar *assets* visuais a partir de conjuntos de dados preexistentes, artistas podem se ver liberados das tarefas mais tediosas e repetitivas, voltando seu foco e criatividade para aspectos mais inovadores e complexos do design de jogos. Esta alteração no paradigma de produção pode resultar em um reaquecimento na inovação dentro do cenário de jogos digitais, à medida que os artistas ganham mais espaço para explorar e inovar.

Além disso, a capacidade das GANs de criar uma ampla variedade de *assets* visuais em um curto período de tempo apresenta uma significativa utilidade prática para pequenas empresas de desenvolvimento e artistas independentes. Isso permite que projetos com orçamentos mais restritos ainda possuam acesso a uma diversidade de recursos visuais, democratizando, de certa forma, o cenário de desenvolvimento de jogos e permitindo que mais criadores possam ver suas visões se tornarem realidades virtuais.

Em suma, o modelo de GANs pode contribuir na construção de *assets* em 2D diversificados e únicos para os artistas.

## 8. Referências

ARANTES, P. **Arte e mídia**: perspectiva da estética digital. São Paulo: Senac, 2005.

BERGER, C. Perceptrons: the most basic form of neural network. **Applied Go**, EUA, 09 jun. 2016. Disponível em: <https://appliedgo.net/perceptron/>. Acesso em: 23 jun. de 2022.

BITTENCOURT, G. **Inteligência artificial: ferramentas e teorias**. Florianópolis; Ed. da UFSC, 1998.

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-dgames-pode-somar-mais-de-us-200-bilhoes/. Acesso em: 6 de jan. de 2022.

CACCIA, L. C. M. *Réseaux de neurones artificiels*. **Accromoth**, EUA, 2018. Disponível em: <http://accromath.uqam.ca/2018/09/reseaux-de-neurones-artificiels>. Acesso em: 6 de jan. de 2022.

CRISTOFFERSON, A.; JAMES, A.; O'BRIEN, A.; ROWLAND, T. Level up: the future of video *games* is bright. **Bain & Company**, Massachusetts, 12 out. 2022. Disponível em: <https://www.bain.com/insights/level-up-the-future-of-video-games-is-bright%20Bain%20&%20%20Company>. Acesso em: 14 fev. 2023.

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.

GALANTER, P. What is generative art? Complexity theory as a context for art theory. In: International conference on generative Art, 2003, Italy. **Anais do Proceedings of the International Conference on Generative Art**, Italy, 2003. p. 1-21.

GOODFELLOW, J. I.; ABADIE, P. J.; MIRZA, M.; XU, B.; FARLEY, W. D.; ORZAIR, S.; COURVILLE, A.; BENGIO, Y. Generative adversarial nets. Ithaca: **ArXiv**, jun. 2014. Disponível em: <https://arxiv.org/abs/1406.2661>. Acesso em: 04 mar. 2022.

GIL, A. C. **Como elaborar projetos de pesquisa**. 7. ed. São Paulo: Atlas, 2022.

GRANDO, N. Neurônios e redes neurais artificiais. **Blog do Nei**. 3 de mar. de 2022. Disponível em: <https://neigrando.com/2022/03/03/neuronios-e-redes-neurais-artificiais/>. Acessado em: 3 de jun. de 2022.

HAMMOND, K. **Practical artificial intelligence for dummies**. Nwe Jersey: John Wiley & Sons, 2015.

HAVALDAR, P.; MEDIONI, G. **Multimedia systems: Algorithms, Standards, and Industry Practice**. Boston: Course Technology, 2020.

HUIZINGA, J. **Homo ludens**. São Paulo, 2020.

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

KENT, S. L. **The ultimate history of video games: from pong to pokémon and beyond - the story behind the craze that touched our lives and changed the world**. New York: Three Rivers Press, 2001.

KUNTAL, G. **Learning generative adversarial networks: next-generation deep learning simplified**. EUA: Packt Publishing, 2017.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, n. 7553, p. 436-444, 2015. Disponível em: <https://www.nature.com/articles/nature14539>. Acesso em: 01 mar. 2023.

LEMOS, A. O que é inteligência artificial e como ela funciona. **Folha de são paulo**, São Paulo. 12 de maio de 2022. Disponível em: <https://www1.folha.uol.com.br/tec/2022/05/o-que-e-inteligencia-artificial-e-como-ela-funciona.shtml>. Acesso em: 3 jun. 2022.

LIESER, W. **Arte digital**. Portugal: Konemann, 2020.

LIMA, L. A. B. Estado da arte da pesquisa sobre a indústria de jogos digitais no Brasil: temáticas correntes e caminhos futuros. **Revista GEMINIS**, v. 14, n. 1, jan./abr., 2023.

LUZ, A. R. **Vídeos games: história, linguagem e expressão gráfica**. São Paulo: Blucher, 2010.

MENDONÇA, F. C. I. Redes neurais convulsionais gerando arte: uma aplicação em obras de Jê Américo. **Monografia**, Universidade de São Paulo, São Paulo, 2019. Disponível: <https://bcc.ime.usp.br/tccs/2018/isacfm/files/monografia.pdf>. Acesso em: 20 jun. 2022.

- MUELLER, J. P.; MASSARON, L. **Machine learning for dummies**. New Jersey: John Wiley & Sons, 2021.
- MÁTARAS, L. R. Artificial intelligence and the Arts: toward computational creativity. In: GREY, A.; ROSSITER, J. (org.). **The next step: exponential life**. EUA: Bbva-Open Mind, 2017.
- NGUYEN, M. H. T. **Fundamentals of 2D game srt**. Oklahoma: Spring, 2021.
- 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-dgames-ultrapassara-us-200-bi-ate-2023/>. Acesso em: 6 de jan. de 2022.
- PHILLIPS, D. **Machine learning: jump on the way to the future, discover artificial intelligence and data science, maximize your business in the modern world mastering deep learning, python and algorithms**. New York: Dan Phillips. 2020.
- RHYS, E.; MICHEIEL, B.; LINDA, T. D.; RAE-WOO, K.; MINH, T. L. N.; HUGO, T.; TIANYI, G.; TOMOFUMI K.; LUCA, C.; GUILHERME, F.; FRANK C.; TIAGO R.; ALEXIS P. **Global games market report**. EUA: Newzoo. 2022.
- ROGERS, S. **Level up: um guia para o design de grandes jogos**. São Paulo: Blucher, 2013.
- RUMELHART, D.; MCCLELLAND, J; **Parallel distributed processing: explorations in the microstructure of cognition**. MIT Press, 1986.
- RUSSELL, S.; NORVIG, P. **Inteligência artificial**. Rio de Janeiro: Elsevier, 2013.
- SALGADO, L. A. Z. **Arte digital**. Curitiba: Intersaberes. 2020.
- SHAHRIAR, S. GAN computers generate arts? A survey on visual arts, music, and literary text generation using generative adversarial network. **ArXiv**, Ithaca, ago. 2021. Disponível em: <https://ieeexplore.ieee.org/document/9507424>. Acesso em: 13 mar. 2023.
- THOMPSON, J. S. **Machine law, ethics, and morality in the age of Artificial intelligence**. Hershey: IGI Global, 2021.
- TIERNAN, J. Is AI really an art and design killer. **Vectornator**, EUA, 18 nov. 2022. Disponível em: [encurtador.com.br/tLSW1](https://encurtador.com.br/tLSW1). Acesso em: 15 fev. 2023.
- TOLCHEVA, S. 6 Ways AI-Generated art is changing the future of art. **MUO**. EUA, 14 out. 2022. Disponível em: <https://www.makeuseof.com/ways-ai-generated-art-changing-future-of-art/>. Acesso em: 15 fev. 2023.
- WILLIAMS, A. **History of digital games: developments in art, design, and interaction**. Focal Press: Focal Press, 2017.
- WILLRICH, R. **Sistemas multimídia distribuídos**. Florianópolis: UFSC, 2000.

### Informações sobre o Artigo

**Resultado de projeto de pesquisa, de dissertação, tese:** resultado parcial de dissertação.

**Fontes de financiamento:** Coordenação de Aperfeiçoamento de Pessoal de Nível Superior.

**Apresentação anterior:** não se aplica.

**Agradecimentos/Contribuições adicionais:** a minha mãe, amigos, orientador e programa.

### Jefferson Valentim

Doutorando no Programa de Pós-Graduação em Informática da Universidade Federal da Paraíba (PPGI/UFPB), Mestre pelo Programa de Pós-graduação em Comunicação e Artes da Universidade Federal da Paraíba (PPGCCA/UFPB).

**E-mail:** jeffersonvalentim2014@gmail.com

**ORCID:** <https://orcid.org/0000-0001-8782-1490>

### Ed Porto Bezerra

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

**ORCID:** <https://orcid.org/0000-0003-4772-9870>