



Universidade Federal da Paraíba
Centro de Informática
Programa de Pós-Graduação em Computação, Comunicação e Artes

JEFFERSON VALENTIM

**O MODELO CONCEITUAL DE REDES ADVERSÁRIAS GENERATIVAS NA
CONSTRUÇÃO DE ASSETS 2D PARA ARTISTAS DE GAMES: UM ESTUDO DE
CASO UTILIZANDO ATIVOS ARTÍSTICOS DO *AXIE INFINITY***

**João Pessoa - PB
Maio/2023**

JEFFERSON VALENTIM

**O MODELO CONCEITUAL DE REDES ADVERSÁRIAS GENERATIVAS NA
CONSTRUÇÃO DE ASSETS 2D PARA ARTISTAS DE GAMES: UM ESTUDO DE
CASO UTILIZANDO ATIVOS ARTÍSTICOS DO *AXIE INFINITY***

Exame de Dissertação apresentado ao Programa de Pós-Graduação em Computação, Comunicação e Artes (PPGCCA) da Universidade Federal da Paraíba, como pré-requisito para obtenção do título de Mestre em Computação, Comunicação e Artes, na linha de pesquisa Arte computacional.

Orientador. Prof. Dr. Ed Porto Bezerra

**João Pessoa - PB
Maio/2023**

Catálogo na publicação
Seção de Catalogação e Classificação

V155m Valentim, Jefferson.

O modelo conceitual de redes adversárias generativas na construção de assets 2D para artistas de games : um estudo de caso utilizando ativos artísticos do Axie Infinity / Jefferson Valentim. - João Pessoa, 2023.
70 f. : il.

Orientação: Ed Porto Bezerra.
Dissertação (Mestrado) - UFPB/CI.

1. Informática. 2. Redes adversárias generativas. 3. Games. 4. Artes. I. Bezerra, Ed Porto. II. Título.

UFPB/BC

CDU 004(043)



Universidade Federal da Paraíba

**PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO, COMUNICAÇÃO
E ARTES**

ATA Nº 1

Aos vinte e seis dias do mês de abril do ano de dois mil e vinte e três, às 16h00min, em uma sala de videoconferência, instalou-se a banca examinadora de dissertação de Mestrado do aluno JEFFERSON VALENTIM. A banca examinadora foi composta pelos professores Dr. NILSON VALDEVINO SOARES, CESAR School, examinador externo à instituição, Dr. YURI DE ALMEIDA MALHEIROS BARBOSA, UFPB, examinador externo ao programa, Dr. TIAGO MARITAN UGULINO DE ARAUJO, UFPB, examinador interno, Dr. ED PORTO BEZERRA, UFPB, presidente. Deu-se início a abertura dos trabalhos, por parte do professor Dr. CARLOS EDUARDO COELHO FREIRE BATISTA, coordenador do Programa, que, após apresentar os membros da banca examinadora e esclarecer a tramitação da defesa, passou a presidência dos trabalhos ao professor Dr. ED PORTO BEZERRA, que de imediato solicitou ao candidato que iniciasse a apresentação da dissertação, intitulada O MODELO CONCEITUAL DE REDES ADVERSÁRIAS GENERATIVAS NA CONSTRUÇÃO DE ASSETS 2D PARA ARTISTAS DE GAMES: UM ESTUDO DE CASO UTILIZANDO ATIVOS ARTÍSTICOS DO AXIE INFINITY. Concluída a exposição, o professor Dr. ED PORTO BEZERRA, presidente, passou a palavra ao professor Dr. NILSON VALDEVINO SOARES, para arguir o candidato, e, em seguida, ao professor Dr. YURI DE ALMEIDA MALHEIROS BARBOSA, e, em seguida, ao professor Dr. TIAGO MARITAN UGULINO DE ARAUJO, para que fizessem o mesmo; após o que fez suas considerações sobre o trabalho em julgamento; tendo sido aprovado o candidato, conforme as normas vigentes na Universidade Federal da Paraíba.

A versão final da dissertação deverá ser entregue ao programa, no prazo de 60 dias. O candidato não terá o título se não cumprir as exigências

Dr. NILSON VALDEVINO SOARES, CESAR



Documento assinado digitalmente

NILSON VALDEVINO SOARES

Data: 30/05/2023 16:13:26-0300

Verifique em <https://validar.it.gov.br>

Examinador Externo à Instituição



Documento assinado digitalmente

YURI DE ALMEIDA MALHEIROS BARBOSA

Data: 31/05/2023 10:33:23-0300

Verifique em <https://validar.it.gov.br>

Dr. YURI DE ALMEIDA MALHEIROS BARBOSA, UFPB

Examinador Externo ao Programa



Documento assinado digitalmente

TIAGO MARITAN UGULINO DE ARAUJO

Data: 30/05/2023 15:34:15-0300

Verifique em <https://validar.it.gov.br>

Dr. TIAGO

O, UFPB

Examinador Interno



Documento assinado digitalmente

ED PORTO BEZERRA

Data: 25/05/2023 16:29:12-0300

Verifique em <https://validar.it.gov.br>

Presidente



Documento assinado digitalmente

JEFFERSON VALENTIM

Data: 31/05/2023 18:27:44-0300

Verifique em <https://validar.it.gov.br>

JEFFERSON VALENTIM



Universidade Federal da Paraíba

**PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO, COMUNICAÇÃO
E ARTES**

Mestrando

Dedico este trabalho a minha mãe e avó, que sempre me apoiaram e me inspiraram a ser a pessoa que sou hoje. Sem o amor e a orientação delas, essa conquista não seria possível. Agradeço por serem minha fonte de força e coragem. Amo vocês duas.

AGRADECIMENTOS

A Deus, por ter me auxiliado grandemente nas dificuldades; por ter me dado forças para continuar em meio a pandemia que levou tantos amigos e colegas.

A minha mãe, Vera de Fátima Valentim, avó Maria de José Farias e meu irmão Luiz Henrique Valentim pelo apoio e suporte em todos os sentidos ao longo da vida.

Ao meu orientador, professor Doutor Ed Porto Bezerra, pela dedicação, paciência, sabedoria, confiança, conhecimentos e pelas suas contribuições ao longo da pesquisa, que me atendeu, inclusive, de forma cordial, em feriados e finais de semana.

Ao professores Doutores da banca examinadora pelas contribuições na Qualificação e na defesa final referente a este trabalho.

A Universidade Federal da Paraíba (UFPB), por ter proporcionado a oportunidade de ser aluno regular do mestrado do PPGCCA. Aos meus colegas de mestrado: Elthon Ferreira Ribeiro e Leandro Ismael pela troca de experiências, dúvidas e todos os dilemas da vida e da pesquisa acadêmica.

Ao coordenador do PPGCCA, professor Doutor Carlos Eduardo Batista, pela disponibilidade e esclarecimentos em diversos momentos durante a minha trajetória no programa.

A todos os professores do Programa PPGCCA e dos programas parceiros pelas contribuições e apontamentos ao longo de todo o Mestrado.

Aos amigos Waldemir Pereira, Iury Zhivago, Vanessa Vera, José Ed, os quais compartilhei momentos e foram os meus parceiros em inúmeras atividades nos últimos anos.

As minhas professoras que indicaram o programa de mestrado.

Muito obrigado a todos que contribuíram diretamente ou indiretamente para que esta pesquisa fosse realizada e concluída.

RESUMO

O mercado de jogos tem experimentado um crescimento vertiginoso nos últimos anos, abrindo espaço para que novas empresas de jogos criem cada vez mais jogos personalizados. Tal fato tem gerado uma grande demanda por *assets* visuais para artistas de games. A presente dissertação faz uma análise do potencial do modelo conceitual de redes adversárias generativas na construção de *assets* 2D para artistas de estúdios de *games*. Para atingir o resultado, foi realizada uma pesquisa utilizando o método científico indutivo e o estudo de caso, bem como a observação direta do fenômeno para gerar as inferências. Uma entrevista com artistas serviu para uma avaliação preliminar do modelo. Descobriu-se que o modelo conceitual pode criar *assets* 2D por meio de um processo adversarial que sintetiza imagens com características reais, a partir de um banco de dados criado por um artista ou desenvolvedor. Isso significa que este modelo de redes pode ser utilizado por artistas como uma ferramenta para criar *assets* 2D ou ser utilizado como suporte para criação de *assets* 2D diversificados. Assim, após este estudo de caso utilizando ativos artísticos do jogo *Axie Infinity*, constatamos que o modelo é promissor para automatizar a produção de artistas em estúdios.

Palavras-chave: Redes adversárias generativas. *Games*. Artes.

ABSTRACT

The games market has experienced a vertiginous growth in recent years, making room for new game companies to create more and more custom games. This fact has generated a great demand for visual assets for game artists. This dissertation analyzes the potential of the conceptual model of generative adversarial networks in the construction of 2D assets for game studio artists. To achieve the result, a survey was carried out using the inductive scientific method and the case study, as well as direct observation of the phenomenon to generate inferences. An interview with artists served as a preliminary assessment of the model. It was discovered that the conceptual model can create 2D assets through an adversarial process that synthesizes images with real features, from a database created by an artist or developer. This means that this network model can be used by artists as a tool to create 2D assets or be used as a support for creating diversified 2D assets. Thus, after this case study using artistic assets from the game Axie Infinity, we found that the model is promising to automate the production of artists in studios.

Keywords: Generative adversarial networks. *Games*. Art.

LISTA DE FIGURAS

Figura 1: Assets visuais em 2D do Axie Infinity.....	18
Figura 2: Obra de Sun Yuan e Peng Yu puxando óleo.....	18
Figura 3: Arte generativa de Pedro Paulo Vecchietti	20
Figura 4: Arte generativa de Manolo Gamboa Naon	28
Figura 5: Unreal engine	29
Figura 6: Tela do Adobe Illustrator	29
Figura 7: Tela do Zbrush	30
Figura 8: God of war 2 (2007).....	32
Figura 9: Axie Infinity (2022)	35
Figura 10: Estrutura de um neurônio e do perceptron	36
Figura 11: Perceptron multicamadas	36
Figura 12: Arquitetura de Redes Neurais Convolucionais	43
Figura 13: Diagrama da arquitetura da GAN	44
Figura 14: Criação de quartos a partir das GANs.....	45
Figura 15: Criação de rostos humanos a partir das GANs	48
Figura 16: Representação Gráfica do Processo de Criação de Personagens	52
Figura 17: Assets visuais 2D do Axie Infinity	53
Figura 18: Resultados variados.....	54

LISTA DE QUADROS

Quadro 1: Modelo de algoritmo de Goodfellow et al, 2014.	42
Quadro 2: Os assets originais e assets sintéticos.....	55
Quadro 3: Perguntas realizadas	57

LISTA DE ABREVIACES

IA – Inteligncia Artificial

GAN – Generative Adversarial Network (Redes Generativas Adversrias)

2D – Duas dimenses

3D – Trs dimenses

API – Application Programming Interface (Interface de Programaco de Aplicaco)

RNA – Redes Neurais Artificiais

SUMÁRIO

1 INTRODUÇÃO	11
1.1 Justificativa e motivação	14
1.2 Objetivos.....	15
1.2.1 <i>Objetivo geral.....</i>	<i>15</i>
1.2.2 <i>Objetivos específicos</i>	<i>15</i>
2 FUNDAMENTAÇÃO TEÓRICA	17
2.1 Arte digital	17
2.1.1 <i>Games.....</i>	<i>21</i>
2.1.2 <i>Assets</i>	<i>22</i>
2.1.3 <i>Games e produção de arte.....</i>	<i>23</i>
2.1.4 <i>O game Axie Infinity</i>	<i>31</i>
2.2. Inteligência Artificial.....	32
2.2.1 <i>Aprendizado de Máquina.....</i>	<i>33</i>
2.2.2 <i>Redes Neurais Artificiais</i>	<i>34</i>
2.2.3 <i>Aprendizado Profundo.....</i>	<i>37</i>
2.2.4 <i>Redes Neurais Convolucionais.....</i>	<i>38</i>
2.2.5 <i>Redes Adversárias Generativas</i>	<i>40</i>
3 PROCEDIMENTOS METODOLÓGICOS	46
4 O ESTUDO DE CASO UTILIZANDO ATIVOS ARTÍSTICOS DO AXIE INFINITY	50
4.1 O Procedimento de Coleta de Dados.....	50
4.2 A criação dos personagens	51
4.3 Análise dos Resultados	54
4.4 Validação Preliminar.....	56
5 CONSIDERAÇÕES FINAIS	60
REFERÊNCIAS BIBLIOGRÁFICAS.....	63
ANEXO I	70

1 INTRODUÇÃO

Nos últimos anos, o mercado de jogos eletrônicos movimentou 175,8 bilhões de dólares (RHYS et al., 2022). A indústria de jogos digitais ascendeu de forma vertiginosa durante a pandemia do SARS-CoV-2 (BULHÕES, 2022). Tal fenômeno ocorreu devido a um conjunto de diferentes fatores como: o isolamento social, a diversificação dos jogos eletrônicos, a popularização de dispositivos móveis e a produção de alta qualidade de jogos. O que culminou na alta demanda por entretenimento virtual.

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 a um 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 faz a novos investidores e empresas que desejam investir no segmento (IBIDEM, 2022). Atualmente, em progressão, a evolução desse quadro culmina na expansão desse mercado e consequentemente o surgimento de novas empresas.

As empresas criadas estão produzindo cada vez mais jogos devido à alta possibilidade de rentabilidade com o cenário econômico. Elas têm produzido para nichos cada vez mais segmentados em resposta ao crescimento da indústria e ao aumento do número de jogadores para esses jogos (IBIDEM, 2022). O que tem gerado uma demanda crescente por profissionais de arte e ativos artísticos, como *assets* visuais. A indústria atual se baseia na automação e interconexão de processos, máquinas e sistemas para criar/desenvolver produtos altamente personalizados e adaptáveis às necessidades das pessoas (SCHWAB, 2019). Ela é impulsionada por tecnologias como a Internet das Coisas (IoT), Inteligência Artificial (IA), *Big Data*, Robótica Avançada, Computação em Nuvem, Realidade Aumentada e Virtual para auxiliar na produção de bens simbólicos e físicos (IBIDEM, 2019). Logo, se baseia no uso de tecnologias que permitem que as empresas sejam mais eficientes, flexíveis e personalizadas, permitindo assim a produção de produtos personalizados como os das empresas de jogos, por exemplo.

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

*games*¹. 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.

No Brasil, a demanda por *assets* visuais como: imagens, personagens, cenários, objetos em 2D e 3D continua 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 a fazer a criação de *assets* visuais desempenham um papel fundamental.

Sistemas como as Redes Adversárias Generativas (GAN) que são arquiteturas digitais os quais compõem um modelo de inteligência artificial. 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. Assim, possibilita que artistas criem conteúdos/imagens que podem ajudar na demanda artística da empresa, gerando imagens, esboços e ideias (MÁTARAS, 2017; TIERNAN, 2022; TOLCHEVA, 2022).

Nessa perspectiva, a presente dissertação que se propõe a investigar o potencial do modelo conceitual de GANs na construção de *assets* visuais em 2D para artistas de *games*. Para isso utilizará os ativos artísticos do game *Axie Infinity* como estudo de caso. Nesse estudo são utilizados os *assets* visuais de personagens do jogo. Essa escolha se justifica pela ascendente troca comercial que existe com esses *assets* e a sua demanda cada vez mais personalizada para jogadores e colecionadores.

O *Axie Infinity* é um *game online* que funciona em duas dimensões e possui uma demanda de *assets* únicos para colecionadores e comercialização. A escolha do game *Axie Infinity* é devida a sua natureza artística. Cada elemento artístico do *game* é único e possui valor simbólico e monetário. Logo, não há repetições de elementos. Ademais, ele fornece *insights* sobre como a tecnologia de GANs é aplicada na criação de personagem de jogos com elementos coloridos e em duas dimensões. Outro fator decisivo para sua escolha é que este game possui mais de 1.000 *assets* que podem ser utilizados no treinamento do modelo de IA adotado pela nossa investigação.

Há trabalhos relacionados com esta pesquisa. O trabalho de Volz et al (2018) utiliza GANs para gerar níveis para o *Super Mario Bros* da Nintendo. Eles utilizam os *assets* visuais

¹ Games são jogos que são jogados em plataformas eletrônicas, como computadores, consoles de videogame, dispositivos portáteis e telefones celulares. Eles envolvem interação do jogador com a interface eletrônica, por meio de controles ou dispositivos de entrada de dados, para controlar personagens, objetos e eventos no jogo.

de nível dos jogos para treinar o modelo. Como resultado, os autores abordam que tiveram com sucesso na criação de novos *assets*, bem como sugerem que o modelo pode gerar uma grande variedade de níveis semelhantes ao do corpus original. Já no trabalho de Sousa (2019) as GANs são usadas na geração de terrenos e paisagens. Ele utiliza o modelo para criar imagens com profundidade e texturas de cor de terrenos com base em exemplos do mundo real. O autor mostra que as GANs são capazes não só de gerar novos terrenos, mas também expandir e conectar terrenos existentes, sugerindo que elas podem criar texturas e paisagens. O trabalho de Hald et al (2020) utiliza o modelo conceitual para gerar *assets* de níveis e de itens para o jogo de quebra-cabeça *Lily's Garden One*. O estudo mostra que o modelo é capaz de gerar esses *assets* de itens e níveis, sugerindo que o modelo possui a capacidade de criar esse tipo de ativo artístico. Por fim, o trabalho de (OLIVEIRA, 2021) propõe que a criação de imagens, utilizando o modelo conceitual de GANs, pode inspirar artistas. Ele sugere que o sistema é capaz de criar obras que inspiram os artistas a produzir novas manifestações artísticas.

Dentro dessa perspectiva de estudos das GANs na criação de artes, a presente dissertação também estuda o potencial do modelo conceitual de redes adversárias generativas na construção de *assets* visuais em 2D para artistas de *games*. Ele busca compreender se de fato este modelo pode auxiliar artistas de *games* e qual o seu potencial na criação de *assets* visuais em 2D de personagens jogos.

Na dissertação é feito um percurso teórico acerca dos temas em foco e uma simulação do modelo. A partir disso, são geradas inferências indutivas do potencial do modelo aplicado a estúdios digitais em um contexto da indústria atual. Essas inferências demonstram que o modelo tem o potencial de automatizar a produção artística para o artista dentro de um estúdio voltado para *games*.

A dissertação está dividida em 6 capítulos. No primeiro capítulo é discutido o percurso utilizado para elaboração da pesquisa; no segundo é abordada a fundamentação teórica. No terceiro capítulo são apresentados os procedimentos metodológicos. O estudo de caso é mostrado no quarto capítulo onde se apresentam a análise e os resultados da avaliação de entrevistas com 50 artistas atuantes em empresas de *games*. No quinto e no sexto capítulos são relatadas, respectivamente, as considerações e os trabalhos futuros.

1.1 Justificativa e motivação

A indústria dos jogos vem crescendo e consecutivamente enfrentando um aumento na demanda por *assets* visuais personalizados que sejam significativos para os jogos (RHYS et al., 2022). Esse aumento de demanda tem sido notado nos últimos anos com a produção e a venda de jogos crescendo constantemente, assim como a venda de ativos artísticos em *games* (RHYS et al., 2022; CRISTOFFERSON et al., 2022). Jogos como o *Axie Infinity*, por exemplo, exigem uma grande quantidade de material artístico personalizado e único para atualização, tornando a produção de *assets* visuais constante e detalhista. Essa demanda elevada pode se tornar um grande problema para artistas e empresas.

Uma solução promissora para atender a essa crescente demanda é o uso de redes generativas adversárias (GANs), um modelo conceitual de inteligência artificial que pode gerar imagens e outras formas de conteúdo visual com base em dados de entrada (JO, 2021). Ao usar GANs na criação de *assets* visuais em 2D, os artistas de jogos podem produzir conteúdo para jogos, esboços e ideias. Além disso, eles podem explorar a criação de *assets* exclusivos e diversificados.

Estudar o potencial das GANs na construção de *assets* visuais em 2D para artistas de estúdios de *games* é essencial para compreender academicamente e acompanhar o novo cenário de produção de arte para jogos. Este cenário está explorando o uso de modelos de inteligência artificial para execução de tarefas e serviços (SCHWAB, 2019; MURPHY & WRITER, 2022; MCGINNIS, 2023).

Nessa perspectiva, a investigação do potencial do modelo conceitual de GANs na construção de *assets* visuais em 2D para artistas de *games* é de grande importância para a indústria dos jogos, para artistas e para a ciência. Já que se trata de um mercado altamente competitivo e em constante mudança, a compreensão e utilização das GANs pode significar uma vantagem competitiva e significativa para as empresas. Além disso, a aplicação dessas técnicas pode levar a um aumento na inovação e criatividade na criação de jogos, o que é fundamental para o sucesso da indústria no contexto da quarta revolução industrial.

Para os artistas de jogos, o estudo das GANs pode permitir a compreensão da criação de *assets* visuais diversificados. Isto resultaria em possível aumento da produtividade e suporte no seu processo criativo. Do ponto de vista acadêmico, a investigação do potencial das GANs na construção de *assets* visuais em 2D pode contribuir para o avanço do conhecimento sobre o uso da inteligência artificial na criação de jogos.

Em suma, para a comunidade artística auxilia na discussão do modelo como uma ferramenta de criação artística contemporânea, englobando as nuances e possibilidades da criação de imagens por meio de uma inteligência artificial. Para as empresas, fornece a visão do modelo como uma ferramenta com potencial para automatizar a criação diversificada de *assets* que por sua vez pode ser manipulada para produção de um banco de imagens utilizáveis em *games*.

1.2 Objetivos

Nesta seção do trabalho serão abordados os objetivos gerais e específicos da pesquisa. Os objetivos gerais representam a finalidade geral da pesquisa e indicam o que se espera alcançar com o estudo. Já os objetivos específicos são os resultados que se pretende obter para atingir o objetivo geral, ou seja, são metas mais detalhadas que orientam a condução da pesquisa.

1.2.1 Objetivo geral

Averiguar o potencial do modelo conceitual de redes adversárias generativas na construção de *assets* visuais em 2D para artistas de *games*.

1.2.2 Objetivos específicos

Investigar a participação histórica de artistas de *games* na produção de artes para jogos ao longo da evolução tecnológica;

Treinar redes adversárias generativas por meio de parâmetros do estudo de caso do game *Axie Infinity*;

Analisar o processo de produção de imagens do modelo de redes adversárias generativas;

Avaliar o resultado do processo de produção de imagens do modelo de redes adversárias generativas.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo aborda os temas fundamentais para compreensão da dissertação. Nele são discutidos os conceitos fundamentais relacionados a arte digital, arte e *games*, bem como os conceitos basilares relacionados à geração de *assets* e às redes neurais generativas adversárias.

2.1 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, ela 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 a 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 que utiliza máquinas capazes de se movimentar e de agir para produzir arte. Nela, os artistas desenvolvem performances e obras por meio da robótica como um novo meio de criação (LIESER, 2020). Eles exploram a modelagem de comportamento mecânico e tornam possível situações interativas em espaços físicos ou telemáticos. Um exemplo desses fenômenos é o dos artistas chineses Sun Yuan e Peng Yu que desenvolveram uma manifestação artística utilizando um robô industrial de seis eixos como pode ser visto na Figura 1.

Figura 1: Obra de Sun Yuan e Peng Yu puxando óleo



Fonte: adaptado de Solomon, 2016

A obra de Sun Yuan e Peng Yu pode ser definida como um ato de expressão artística. Um ato em que um robô feito de aço inoxidável, borracha, éter de celulose, sensor de reconhecimento visual, vidro acrílico, moldura de alumínio performa uma determinação ação na 58ª Bienal de Veneza (SOLOMON, 2016). Nessa ação, a obra denominada de *Can't Help*, por meio do seu algoritmo performa um ato de sobrevivência, força e simpatia em meio ao fim de sua vida mecânica. A máquina funciona por meio de um líquido hidráulico de cor vermelho-sangue que vai parando de funcionar à medida que o líquido esvai.

Outro conceito imerso na arte digital é a manifestação generativa. A arte generativa é uma manifestação que produz arte de forma autônoma. Ela é uma prática na qual o artista cria um processo, um conjunto de regras na linguagem de programação ou em um programa de computador, ou outro mecanismo, que então é colocado em movimento em 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 (Figura 2).

Figura 2: Arte generativa de Pedro Paulo Vecchietti




Fonte: Peña- Bickley, 2021

Esta obra é fluida 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* que faz 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 (Figura 3).

Figura 3: 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 reflete 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 artistas criarem conceitos, paradigmas e construírem 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*, generativa *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.

2.1.1 Games

A Enciclopédia Britânica (BRITANICA, 2023) assim define jogo eletrônico “jogo eletrônico, também chamado de jogo de computador ou videogame, qualquer jogo interativo operado por circuitos de computador. As máquinas, ou plataformas, nas quais os jogos eletrônicos são jogados incluem computadores pessoais e compartilhados de uso geral, consoles de fliperama, consoles de vídeo conectados a televisores domésticos, máquinas de jogos portáteis, dispositivos móveis, como telefones celulares e redes baseadas em servidores”. Ademais, esta enciclopédia define que “O termo videogame pode ser usado para representar a totalidade desses formatos, ou pode se referir mais especificamente apenas a jogos jogados em dispositivos com telas de vídeo: televisão e consoles de fliperama.” (BRITANICA, 2023). Nesta dissertação escolhemos o termo *game* para nos referirmos ao jogo eletrônico.

Os *games* são uma forma de entretenimento interativo. Eles podem ser jogos de ação, aventura, estratégia, educação e simulação. Eles também podem ser jogados sozinhos ou com outras pessoas em modo *multiplayer online*. Atualmente, para além do entretenimento, os *games* são uma das manifestações artísticas mais disseminadas e consumidas no mundo. Esse fenômeno ocorre porque eles se tornaram uma forma de manifestação bastante popular, contando com milhões de jogadores em todo o mundo (CRISTOFFERSON et al., 2022).

Eles também oferecem aos jogadores oportunidades de explorarem mundos virtuais com narrativas visuais, construções estéticas e sonoras exclusivas para os usuários. Nesse contexto, crianças, jovens e adultos interagem com essas manifestações artísticas que representam seus interesses em determinados assuntos que podem ser acerca de momentos da história ou fantasias criadas para interagir com o jogador.

A interação nos *games* ocorre por meio de sistemas multimídias: sistemas que incorporam diferentes tipos de mídia digitalizadas (áudio, imagens, vídeos) usando

hardwares inteligentes para interação (HAVALDAR & MEDIONI, 2010). Esses sistemas possibilitam aos *games* funcionarem com arquivos de músicas, ilustrações, roteiros, animações e mecânicas programáveis em uma única manifestação artística que possui diferentes elementos artísticos de diversos profissionais concatenados. Eles são criações multimidiáticas desenvolvidas para sistemas digitais diversificados que concatenam elementos artísticos de diversos autores em uma só obra (VALENTIM, 2021).

2.1.2 Assets

Os *Assets* são elementos artísticos que compõem os *games*. Eles podem ser de diferentes naturezas como sonoros, mecânicos e visuais. Os *assets* 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 uma 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. Esses *assets* sonoros são criados em *softwares* especializados de produção de áudio, como o *Adobe Audition*, *Kristal Audio Engine*, *Ableton Live* e o *FL Studio*, e 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 *games* (NGUYEN, 2021). Eles podem ser personagens, cenários e itens utilizados no *game* (ROGERS, 2013). Eles são imagens que vão compor o *game* e são criados em *softwares* como *Adobe Photoshop*, *CorelDRAW*, *Illustrator*. 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 de 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*. Esses *pixels* são o menor elemento de resolução da imagem representados por *bits* (WILLRICH, 2000; HAVALDAR & MEDIONI, 2010). Os *bits*, nos *assets*, 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 as modificam. Nesse contexto, os *assets* em 2D também podem ser compreendidos como matrizes numéricas compostas de *bits* e seus múltiplos.

Uma matriz que é utilizada em *games* para explorar ambientações, elementos artísticos, interfaces e narrativas que gerem experiências para o usuário. Experiências formativas, profissionalizante (sérias), artísticas, de lazer e entretenimento em um ambiente imersivo. Um que é pensado e estruturado envolvendo arte e toda uma indústria de produção a cada época.

2.1.3 Games e produção de arte

Desde o seu surgimento, em 1959, os *games* 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 (WILLIAM, 2017; HUIZINGA, 2020).

Um fenômeno que é estudado por diferentes correntes teóricas e campos científicos como: Comunicação, Computação, Ciências da Educação, Economia, Administração e as Artes. Tal fenômeno 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.

Atualmente, os *games* são criados por estúdios digitais (empresas de jogos) em um contexto industrial, de grande escala, diferentes demandas e são composições artísticas multimidiáticas criadas por diversos artistas em uma manifestação única ou seriada. Eles são produzidos por especialistas em diferentes habilidades do meio artístico e tecnológico. Habilidades de produção de roteiro, músicas, sons e ilustrações. Essas habilidades são os elementos-chave que proporcionam materialidade constitutiva ao jogo.

Nesse contexto, apresentaremos um histórico acerca da participação do artista na condição de produtor de arte para *games*. Para traçar esse fenômeno, nos baseamos em elementos que possibilitam a demanda do artista nessa condição dentro de uma empresa de *games*. Assim, os elementos adotados foram o processo de industrialização dos *games* e a evolução tecnológica dos componentes dos *games*. Tal escolha ocorre devido a arte digital que está atrelada diretamente ao desenvolvimento de tecnologias digitais, bem como o processo de industrialização dos *games* que possibilitam a criação de uma demanda por profissional que crie artes cada vez mais sofisticadas para os sistemas comercializados. Assim, traçamos um percurso da inserção do artista e sua produção.

Em um primeiro momento do processo de desenvolvimento artístico para *games*, não havia uma produção fabril deles ou uma empresa constituída de grandes proporções, ou seja, o processo de desenvolvimento dos *games* era de responsabilidade de universidades e laboratórios (KENT, 2001). Na época, o visual era minimamente pensado devido a impossibilidade de criar representações de objetos e mecânicas rebuscadas. Os *games* deste período eram produzidos por pesquisadores das ciências exatas como afirma Luz (2021), William (2017), Kent (2001). Por exemplo, o *game Tennis for Two* foi criado para ser exibido em monitor de osciloscópio e o *game Spacewar!* foi programado em *Assembly* (linguagem de programação de baixo nível) e executado em um computador DEC – PDP 1 (BATISTA et al, 2007; SOUZA & ROCHA, 2005; LUZ, 2021).

Em um segundo momento do processo de desenvolvimento artístico para *games*, houve a industrialização dos *games*, período conhecido como a era dos arcades (HERZ, 1997; WILLIAM, 2017; LUZ, 2021). Inicia-se uma produção industrial dos *games* devido a produção seriada e a geração de uma demanda intelectual para criação e reprodução de

elementos que compõem os *games*. A produção de arte era predominantemente criada por engenheiros por meio da manipulação direta nos *games*, ou seja, e a participação dos artistas ainda não era significativa (LAPETINO, 2016). Os *games* eram predominantemente desenvolvidos por especialistas das engenharias que não tinham formação em arte ou *design*, porém iniciava-se timidamente a participação de artistas no processo de criação de *games*. Embora a participação dos artistas ainda não fosse tão significativa, o início de sua participação é visto em casos isolados. Por exemplo, o jogo "Space Invaders" (1978), criado por Tomohiro Nishikado, contou com a contribuição do artista Hiroshi "Pop" Yamauchi para o *design* dos alienígenas do jogo.

Em um terceiro momento do processo de desenvolvimento artístico para *games*, a produção de artes ainda era feita de forma rudimentar e predominante por engenheiros de forma direta nos *games*, como uma entidade singular, com casos isolados de artistas. Nos estúdios não havia *softwares* exclusivos para a produção artística, embora já houvesse a comercialização de consoles domésticos como o Magnavox Odyssey, Atari 2600 e Intellivision. (HERZ, 1997; LUZ, 2021). A limitação de recursos tecnológicos impedia o desenvolvimento de aplicações capazes de produzir uma manifestação artística de capacidade representativa de alta fidelidade. Desse modo, a construção dos elementos em cena era em sua maioria de formas geométricas e os elementos artísticos eram construídos com base em sua função (não havia características figurativas ou representacionais). Isto não gerava uma demanda generalizada por especialistas em artes.

Em um quarto momento do processo de desenvolvimento artístico para *games*, os *games* passaram por uma evolução significativa no que tange a produção artística. Com a introdução de microprocessadores nos consoles, os *games* puderam ser projetados em melhores condições gráficas (HERZ, 1997; LUZ, 2021). Isto ocasionou um avanço gráfico e o rompimento da construção em conjunto dos componentes dos *games*. Tal rompimento proporcionou a separação da criação de *hardware* e *software* nos *games* (LUZ, 2010). Os *hardwares* passaram a ser construídos por sujeitos dotados de habilidades e conhecimento técnico (engenheiros) e os *softwares* por aqueles que tivessem domínio técnico e conhecimento gráfico do que seria representado (engenheiros e programadores). Essa separação resultou em uma maior dedicação ao desenvolvimento artístico nos *games* e o surgimento de avatares. Logo, as imagens e os avatares adquiriram formas menos abstratas, pois foram produzidos em formas humanoides e de animais. Todavia, ainda eram pequenas figuras recortadas em papelão, sem movimentação ou animação de longa duração, bastante sintéticas e abstratas (WILLIAM, 2017; LUZ, 2010). Como exemplo, é possível mencionar

os jogos E.T (1982), Superman (1979) e Pitfall (1982). No entanto, a participação dos artistas na produção de *games* começou a se tornar mais relevante. As empresas passaram a investir na apresentação visual dos jogos com *designs* de gabinete, arte promocional e alguns jogos contavam com a contribuição de artistas para o *design* de personagens, cenários e elementos gráficos. Um exemplo importante é o jogo "Donkey Kong" (1981), criado por Shigeru Miyamoto e Gunpei Yokoi. Miyamoto, considerado um dos maiores artistas do mundo dos jogos eletrônicos, foi responsável pelo *design* de personagens e cenários do jogo, enquanto Yokoi se encarregou da programação e do *hardware*. "Donkey Kong" teve um impacto significativo na evolução dos *games*, ajudando a consolidar a participação dos artistas na produção de jogos.

Em um quinto momento do processo de desenvolvimento artístico para *games*, houve a transformação do microprocessador em *commodity*, bem como o avanço tecnológico tornou a produção de arte para os *games* mais relevante. A atuação do artista já era constante e, com a inserção do microprocessador de 8 *bits* nos *games*, ocasionou uma quebra de paradigma com a intensificação da criação de artes para os *games* (WOLF, 2012; LUZ, 2010). Empresas como a Coleco, a Sega e a Nintendo utilizaram o microprocessador de forma dedicada ao processamento gráfico de vídeo e memória para controlar o que acontecia em tela (LUZ, 2010; WOLF, 2012; WILLIAM, 2017). O resultado foi o estabelecimento da tecnologia de *Bitmapping* que permitiu o endereçamento de cada *pixel* na tela, possibilitando o tratamento de cada um como um ponto em uma malha imagética com cor e luminância independentes. Além disso, essa tecnologia propiciou que os artistas realizassem uma maior inserção de ativos visuais simultâneos em tela. Ademais, a evolução da capacidade de processamento da imagem possibilitou que engenheiros desenvolvessem *softwares* para produção artística de *games* nas empresas. Com isso, os artistas ganharam sistemas dedicados ao desenvolvimento (LUZ, 2010). Esse fenômeno favoreceu a criação e reaproveitamento de elementos artísticos durante todo o desenvolvimento dos *games*, assim como a reciclagem de códigos de movimentação de personagens evitando criar tudo do zero. O reaproveitamento de elementos artísticos e códigos favoreceu o surgimento de metodologias para produção de um jogo nos estúdios. Os profissionais das artes de *games* passaram a reutilizar cenários, itens e até personagens na criação de novos jogos (LUZ, 2010; WILLIAM, 2017). Essa reutilização foi idealizada no intuito de maximização do tempo de produção dos *games* para a indústria.

Nesse contexto, é possível destacar o surgimento de *softwares* dedicados à criação de artes e a necessidade de um método para criação de jogos pelo artista, assim como a

comercialização de jogos com traços artísticos semelhantes. O jogo Super Mario Bros da Nintendo (1985 e 1987) teve os ativos artísticos reutilizados (LUZ, 2010).


Em um sexto momento do processo de desenvolvimento artístico para *games*, o microprocessador de 16 bits foi inserido nos consoles possibilitando significativo progresso na representação artística dos jogos e criação (LUZ, 2010; WILLIAM, 2017; PARISH, 2018). Isso ajudou o artista na criação de elementos com maiores paletas de cores, detalhamento, bem como a customização de cenas nos jogos. Uma das inovações do período é a criação dos gráficos em 2,5 dimensões. Nele, os artistas e desenvolvedores faziam o desenvolvimento desse tipo de arte por meio de alterações diretamente no *hardware* para escalonar figuras e sprites do jogo em tela. Desse modo, as imagens criadas aparentavam estar em três dimensões. Um exemplo desse fenômeno é o jogo “F-zero” de 1990. Ademais, os jogos passaram a ser predominantemente produzidos em CD-ROM. Isto possibilitou maior memória de arquivamento de informações para os artistas puderem criar produções mais robustas. Nessa perspectiva, houve um aprofundamento das histórias, ambientações, narrativas e melhoria gráfica/artística nos *games* comercializados (LUZ, 2010; WILLIAM, 2017; PARISH, 2018). Eles passaram a ter mais detalhes nos avatares, assim como obtiveram maiores roteiros de produção. Um exemplo é o jogo Sonic The Hedgehog (1991).

No sétimo momento do processo de desenvolvimento artístico para *games*, o processador de 32 bits foi inserido nos dispositivos de jogos. Os artistas puderam explorar novas linguagens na criação dos *games*, bem como ferramentas mais potentes pelo poder de processamento maior. Além disso, os consoles passaram a ser acompanhados de coprocessadores especializados em cálculos poligonais, úteis para simulação 3D (LUIZ, 2010). Os consoles de 32 bits trouxeram a tridimensionalidade, possibilitando novas oportunidades de atuação do artista na indústria dos *games*. As empresas desenvolvedoras de jogos passaram a licenciar e comercializar os núcleos dos jogos já desenvolvidos. Esse fenômeno começou a ocorrer primeiramente com os núcleos do “Doom”, de 1994, e “Quake”, de 1996 (WILLIAM, 2017; LUIZ, 2010). O jogo “Doom” espalhou-se em toda a industrialização do desenvolvimento de jogos da época. O resultado dessa movimentação foi a comercialização nos núcleos sobre o nome de *game engine* (motor de *games*).

O motor de *games* pode ser compreendido como um *framework*. Um *software* que possui um conjunto de bibliotecas de códigos responsáveis por simplificar o desenvolvimento de jogos e criação artísticas. Nele, há especificações gráficas para renderizar gráficos 2D ou 3D, especificações para emular a física, as animações e a colisão. Por meio dele, houve separação das partes gráficas e da física. O artista ficou responsável pela criação gráfica e o

desenvolvedor pela parte física. O *game engine* possibilitou maior liberdade para o artista nos estúdios, pois poderia usufruir de elementos já criados para produção e explorar novas perspectivas artísticas como criar, editar e deformar elementos de diferentes ângulos para compor o objeto artístico de um jogo. Um exemplo desse fenômeno pode ser visto na Figura 4 com a *Unreal engine*.

Figura 4: *Unreal engine*




Fonte: Brito (2016)

Uma árvore está sendo editada e colocada no cenário do jogo. Essa árvore foi criada por um artista e está sendo reutilizada na produção de um novo cenário. Esse fenômeno aconteceu no período e perdura até os dias atuais devido à grande demanda de elementos que se adequem a determinados jogos em tempo hábil. Neste contexto, as *engines* também possibilitaram que os artistas pudessem utilizar outro *software* de criação de artes e inserir no desenvolvimento do jogo.

Em um oitavo momento do processo de desenvolvimento artístico para *games*, os artistas puderam explorar diversas formas de criação artística. A evolução dos processadores e o armazenamento de memória possibilitaram às empresas desenvolverem diversas *games engines* que aceitavam criações artísticas de outros *softwares* como a *Unity*, *CraftStudio*, *Godot* e a nova versão da *Unreal*. Surgiram ferramentas que criam arte em duas dimensões, tais como *Adobe Photoshop*, *CorelDraw* e *Adobe Illustrator*. A Figura 5 mostra uma tela do *Adobe Illustrator*.

Figura 5: Tela do Adobe Illustrator




Fonte: Produzida pelo autor a partir do *Adobe Illustrator*

Na Figura 5 é possível ver o *Adobe Illustrator* com elementos artísticos criados para *games*. Esse *software* é comumente utilizado na criação de ilustrações em 2D para animações e para criação de artes para jogos. Ele demanda uma extensa combinação de elementos para criação de *assets*. Demanda uma combinação de cores, criatividade por parte do artista, conhecimento de formas geométricas, habilidade motora do artista e outras variáveis necessárias para criar elementos artísticos na contemporaneidade.

Surgiram também *softwares* de criação artística que criam em três dimensões, tais como *Maya*, *3ds Max*, *Cinema 4D* e o *Zbrush*. Na Figura 6 é possível ver uma tela do *Zbrush*.

Figura 6: Tela do *Zbrush*



Fonte: Produzida pelo autor a partir do *Zbrush*

O *software Zbrush* é comumente utilizado na criação de personagens e itens para filmes de animações, assim como *games* em 3D. Ele também é um *software* que demanda bastante conhecimento técnico do artista para produzir com combinação de paletas, sombras, formas e toda sua estrutura. Ademais, as representações artísticas criadas nesses *softwares* de criação artística, tanto em 2D como em 3D, podem ser utilizadas nos *games engines*. Isto proporcionou bastante liberdade ao artista para expandir a produção.

A produção de arte para jogos utilizando *softwares* externos possibilitou ao artista criar elementos ricos em detalhes. Ele pode, por exemplo, criar rosto de avatares e detalhar sobrancelhas, cabelo, óculos, assim como os demais elementos do corpo e outros itens utilizados nos jogos. O lado positivo foi o aumento de detalhes nos itens dos jogos. Todavia, houve uma maior demanda trabalhista para o artista, assim como exigências para manter um estilo conceitual durante toda a obra. Com isso, os artistas tinham que produzir com o máximo de detalhes possíveis e não sair do conceito artístico elaborado para o jogo. Tal fenômeno gerou uma dependência do artista para concluir cada trabalho.

Esse momento também ficou marcado pela inserção do processador de 64 bits nos consoles, assim como maior utilização do DVD na criação de jogos. Essas duas tecnologias propiciaram avanços gráficos e maior quantidade de armazenamento. Um exemplo desse fenômeno é o jogo *God of War 2* lançado em 2007 para *PlayStation 2* que funcionava com dois chips de 64 bits (Figura 7).

Figura 7: *God of war 2* (2007)



Fonte: Produzida pelo autor a partir do jogo *God of War 2*

O jogo *God of War 2* é um jogo de ação e aventura produzido pela Santa Monica Studio. Ele é ambientado na Grécia antiga.

No último momento do processo de desenvolvimento, que envolve os dias atuais, as *game engines* e os *softwares* de criação artística ficaram acessíveis para todos os públicos. A evolução dos *consoles* e dispositivos passaram a aceitar diferentes mídias de armazenamento

de jogos, bem como arquivos de *games* contidos em memória *flash* ou armazenados em nuvem. Com isso, diferentes estúdios e pessoas independentes poderiam produzir jogos.

A produção artística atual para *games* varia bastante, dependendo do tipo de *game* e da equipe de desenvolvimento. Isto culmina por vezes em demanda por *assets* que pode ser contínua ou sazonal. Uma demanda contínua exige do artista uma produção para constantes atualizações. Uma demanda sazonal exige produção para eventos, datas comemorativas ou ainda atualizações de outras datas e elementos que ajudam na construção do roteiro do *game*. Estes elementos possuem uma significância artística que descreve ou dá sentido ao que acontece em tela. Um exemplo desse fenômeno é o caso do jogo *Journey* que teve seus *assets* produzidos em alta significância. Outro exemplo são os jogos em que os elementos artísticos possuem *token* criptográfico não fungível que representa um ativo artístico exclusivo devido a sua compra por colecionadores. Em outros termos, jogos que possuem elementos artísticos como avatares e itens com registro de autenticidade virtual que pode ser verificado por qualquer pessoa dentro da mesma rede. Esses elementos se tornam únicos e podem ser trocados entre os jogadores ou ainda serem vendidos.

2.1.4 O *game Axie Infinity*

O *Axie Infinity* é um jogo baseado em criaturas, chamadas *Axies*, que são animais fantásticos que podem ser comprados, vendidos e negociados pelos jogadores como ativos digitais. Cada ativo é exclusivo.

A produção de arte do *Axie Infinity* é feita pela equipe de produção artística da empresa vietnamita *Sky Mavis* e por parcerias com artistas convidados para criação de estilos e detalhes. Jeffrey Zhai, um artista conceitual e ilustrador de personagens e Mau Borja, um artista filipino, são artistas que contribuíram com a arte do *Axie Infinity*. A colaboração com artistas permitiu que o *Axie Infinity* apresentasse uma ampla variedade de estilos de arte e criasse uma comunidade engajada em colecionar os *Axies* e itens do universo dos *Axies*. Existe uma demanda artista sazonal para eventos e atualizações.

A produção de *assets* visuais em 2D do *Axie Infinity* é feita por meio de *softwares* que criam artes em duas dimensões (como *Adobe Photoshop* ou *Adobe illustrator*) e são exportados para serem usados no jogo. Cada *asset* possui uma cor e um detalhe diferente.

O *Axie Infinity* é um *game* que movimenta milhões de dólares ao ano com seus elementos artísticos. Ele é um jogo em que os ativos artísticos são comercializados e se

tornam propriedade dos jogadores. A aquisição desses *assets* no *game* pode ser feita de três formas. A primeira envolve a compra diretamente na loja do jogo. A segunda envolve a troca ou comercialização de *assets* pelos jogadores e a terceira pela coleta randômica dos itens que podem ser fornecidos ao jogador. A Figura 8 mostra uma tela da loja de compra e venda de *Axies*.

Figura 8: *Axie Infinity* (2022)

Listado recentemente	Vendido recentemente
Eixos Terra Itens Pacotes # 2170263 Contagem de raças: 3 44 55 35 30 0,009 \$ 10,96 em um minuto	Eixos Terra Itens Pacotes # 10597490 Contagem de raças: 0 COMPRADOR Lunático #0 (ronin...60b54a) VENDEDOR Lunático #0 (ronin...74cabe) 0,008 US\$ 9,33 em um minuto
# 4394084 Contagem de raças: 3 61 31 31 41 0,008 US\$ 9,33 em um minuto	# 3273057 Contagem de raças: 4 COMPRADOR Lunático #1 (ronin...eb23c4) VENDEDOR Faydz (ronin...a9882b) 0,005 \$ 5,83 em poucos segundos
# 10754785 Contagem de raças: 2 45 57 35 27 0,01 \$ 11,66 em um minuto	# 10620426 Contagem de raças: 2 COMPRADOR Lunático #3464047 (ronin...52d676) VENDEDOR nadrohiwol (ronin...9daa8d) 0,006 US\$ 6,59 em poucos segundos
# 10550581 Contagem de raças: 2 30 59 35 40 0,05 \$ 58,31 em um minuto	# 3625341 Contagem de raças: 2 COMPRADOR Lunático #23214010 (ronin...f8006c) VENDEDOR Miguel Mestre (ronin...b309f6) 0,006 US\$ 7,00 em poucos segundos
# 9807917 Contagem de raças: 0 44 55 35 30 0,029 \$ 33,82 em um minuto	# 8630858 Contagem de raças: 4 COMPRADOR JJD Axie (ronin...5d7204) VENDEDOR Cabana de teste ... (ronin...d28806) 0,025 \$ 29,16 em poucos segundos
# 4796043 Contagem de raças: 3 40 43 31 50 0,008 US\$ 9,80 em um minuto	# 7366508 Contagem de raças: 3 COMPRADOR <F45C1A> Miguel... (ronin...118b7e) VENDEDOR Picasso (ronin...d74541) 0,007 \$ 8,10 Alguns segundos atrás
# 11327220 Contagem de raças: 0 32 40 31 61 0,3 \$ 349,71 em um minuto	# 1549625 Contagem de raças: 0 COMPRADOR Lunático #249503... (ronin...292fb5) VENDEDOR 1 (ronin...7fdd96) 0,007 US\$ 8,70 Alguns segundos atrás
# 7570716 Contagem de raças: 3 47 51 27 39 0,018 \$ 21,48 em um minuto	# 406358 Contagem de raças: 5 COMPRADOR Lunático #235025... (ronin...426f97) VENDEDOR Genjutsu (ronin...fadde2) 0,008 US\$ 9,85 Alguns segundos atrás
# 7794421 Contagem de raças: 3 61 32 31 40 0,03 \$ 34,87 em poucos segundos	# 9955551 Contagem de raças: 3 COMPRADOR Mfernando l Proc... (ronin...49f9b4) VENDEDOR Picasso (ronin...d74541) 0,006 US\$ 6,83 Alguns segundos atrás

Fonte: Produzida pelo autor a partir do jogo *Axie Infinity* em 2022

Os personagens são vendidos em dólares ou *Ether*, uma moeda digital que possui valor flutuante. Na Figura 8 se percebe que cada ativo artístico é único em sua forma. Eles possuem cores, detalhes e formas que os tornam únicos e sem repetições. Esse fenômeno torna o avatar único e colecionável para os jogadores. Isso provoca a necessidade de produção de novos ativos para serem disponibilizados.

2.2. 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 formatadas em código (RUMELHART & MCCLELLAND, 1986; BITTENCOURT, 1998).

O agente inteligente pode ser do tipo forte ou fraco. O agente fraco ou modelo de inteligência fraca é a 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 não existe, ele é apenas um conceito filosófico (HAMMOND, 2015; MUELLER, 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 as que desempenham suas atividades com base em um aprendizado de máquina, redes neurais artificiais e aprendizado profundo.

2.2.1 Aprendizado de Máquina

O aprendizado de máquina (*Machine Learning*) é uma subárea da Inteligência Artificial que permite as máquinas aprenderem a partir de dados, sem a necessidade de serem explicitamente programadas (SAMEUL, 1959). Segundo Jordan e Mitchell (2015), o objetivo do *Machine Learning* é desenvolver algoritmos que possam ser treinados para realizar tarefas específicas com base em dados, sem precisar de instruções explícitas. Isso a torna uma

abordagem poderosa para resolver problemas complexos em diferentes áreas, incluindo a criação de arte para *games*.

Existem três formas principais de aprendizado de máquina: aprendizado supervisionado, aprendizado não supervisionado e aprendizado por reforço.

De acordo com Goodfellow, Bengio e Courville (2016), o aprendizado supervisionado é usado quando se tem dados rotulados, o que significa que já foram classificados ou etiquetados por um ser humano. O objetivo é treinar o modelo para que ele possa prever a classificação correta de novos dados. Exemplos de aplicações de aprendizado supervisionado incluem reconhecimento de voz, reconhecimento de imagem e previsão de preços de ações.

Por outro lado, o aprendizado não supervisionado é usado quando se tem dados não rotulados. Conforme mencionado por Alpaydin (2020), o objetivo é encontrar padrões e estruturas nos dados sem a orientação de um rótulo. Podemos citar como exemplos de aplicações de aprendizado não supervisionado: segmentação de clientes em grupos com base em seus hábitos de compra e identificação de tópicos em grandes conjuntos de dados de texto.

O aprendizado por reforço, conforme descrito por Sutton e Barto (2018), é usado quando se tem um agente que está interagindo com um ambiente e aprendendo a partir das recompensas e penalidades recebidas. O objetivo é treinar o agente para tomar ações que maximizem a recompensa a longo prazo. Exemplos de aplicações de aprendizado por reforço incluem a robótica e os jogos de computador.


2.2.2 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 (Figura 9).

Figura 9: Estrutura de um neurônio e do *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 (Figura 10).

Figura 10: *Perceptron* multicamadas



Fonte: Produzida 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 *perceptron* de multicamadas funciona em um processo de *feed forward*. Esse processo sempre segue um modo progressivo onde não há um fluxo de retorno. Dessa forma, ele funciona em um fluxo de entrada (*input layer*) que passa por uma quantidade variável de camadas ocultas (*hidden layer*) para alcançar um resultado (*output layer*) que possa ser efetivo (BERGER, 2016) para o funcionamento da rede e treinamento.

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 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. 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 o modelo de redes adversárias generativas (Seção 2.2.5).

2.2.3 Aprendizado Profundo

O aprendizado profundo (*Deep Learning*) é uma técnica de aprendizado de máquina que utiliza redes neurais artificiais com múltiplas camadas para aprender a representação dos dados (GOODFELLOW et al., 2016). Segundo Bengio et al. (2013), a ideia do *Deep Learning* é utilizar o aprendizado em múltiplos níveis de abstração para adquirir conhecimento sobre representações de dados cada vez mais complexas.

As redes neurais artificiais são a base do *Deep Learning*. Elas consistem em camadas de neurônios interconectados que realizam operações matemáticas para gerar saídas a partir de entradas (LECUN et al., 2015). Uma rede neural profunda, por sua vez, possui múltiplas camadas de neurônios, permitindo a representação de dados mais complexos.

O treinamento de uma rede neural profunda envolve a atualização dos pesos das conexões entre os neurônios a partir dos dados de entrada e saída (GOODFELLOW et al., 2016). Esse processo é realizado por meio do algoritmo de *backpropagation*, que propaga o erro na saída da rede de volta para as camadas anteriores, permitindo que os pesos sejam ajustados de forma a minimizar o erro.

O *Deep Learning* tem sido utilizado em diversas aplicações, como o reconhecimento de imagem e voz, o processamento de linguagem natural, a análise de dados e muitas outras áreas (LECUN et al., 2015). Uma das principais vantagens do *Deep Learning* é sua

capacidade de aprendizado em múltiplos níveis de abstração, permitindo a representação de dados cada vez mais complexos e abstratos.

Um tipo de rede neural profunda muito utilizada em tarefas de visão computacional é a Rede Neural Convolucional que é especialmente projetada para extrair características de imagens e vídeos.


2.2.4 Redes Neurais Convolucionais

As redes convolucionais, também conhecidas como CNNs (Convolutional Neural Networks), são um tipo de modelo de aprendizado profundo amplamente utilizado para tarefas relacionadas às imagens tais como classificação, segmentação e detecção de objetos. Esses modelos são baseados em camadas convolucionais que são capazes de extrair características das imagens de entrada e, posteriormente, usá-las para fazer previsões precisas sobre elas.

De acordo com Mendonça (2019), as CNNs são compostas por várias camadas de processamento de imagens, organizadas em uma hierarquia crescente de abstração. Cada camada age como um filtro que extrai uma determinada característica da imagem original presente no arquivo de entrada. Ao aplicar esses filtros em conjunto, a CNN pode gerar uma imagem de saída que consiste em um mapa de diferentes atributos filtrados dessas características (LEON et al. 2015).

A arquitetura da CNN, conforme Lecun et al. (2015), foi inspirada na forma como o córtex visual do cérebro humano processa informações visuais. As camadas convolucionais imitam o comportamento de células do córtex visual que são capazes de detectar características simples, como bordas e texturas, e combiná-las para formar características mais complexas.

A arquitetura da rede neural consiste em uma série de camadas, cada uma executando quatro operações principais: convolução, não linearidade, *pooling* e camadas totalmente conectadas (Figura 11).

Figura 21: Arquitetura de Redes Neurais Convolucionais

Fonte: Criada com base em Mendonça (2019)

De acordo com Goodfellow et al. (2016), cada camada da rede realiza uma série de operações essenciais para o seu funcionamento. A convolução é uma operação que permite extrair características relevantes da imagem de entrada, preservando a relação espacial entre os *pixels*. Os filtros de convolução aplicados nesta camada são operações matemáticas cuja definição é determinada pela rede durante o processo de treinamento. Ao agrupá-los em diferentes etapas do processo, a rede neural se torna capaz de reconhecer informações mais abstratas e profundas de uma imagem por meio de um processo de aprendizado hierárquico (MENDONÇA, 2019).

A camada de não linearidade é geralmente utilizada após a camada de convolução em uma rede neural convolucional com o objetivo de introduzir um componente não linear. Isso aumenta a capacidade da rede de representar informações complexas (GOODFELLOW et al., 2016). Uma das operações mais comuns nessa camada é a função de ativação ReLU (*Rectified Linear Unit*) que substitui *pixels* de valor negativo por zero. Ela pode ser escrita como “ $f(x) = \max(0, x)$ ”. Além disso, outras funções de ativação como *Tanh* (Tangente Hiperbólica) e sigmoide também podem ser utilizadas nesta camada (MENDONÇA, 2019).

A função de ativação ReLU é uma das mais populares em redes neurais convolucionais devido à sua simplicidade e eficácia em reduzir o problema de desvanecimento de gradientes (GLOROT et al., 2011). A função *Tanh* é uma função *sigmoidal* simétrica que retorna valores entre -1 e 1, enquanto a função sigmoide é uma função *sigmoidal* que retorna valores entre 0 e 1. Essas funções de ativação são adequadas para problemas de classificação binária ou multi-classe, mas podem levar ao problema de desvanecimento de gradientes em redes mais profundas (BENGIO et al., 1994). Portanto, a escolha da função de ativação depende do problema que está sendo resolvido e da estrutura da rede neural convolucional. A ReLU é geralmente recomendada como uma boa escolha

para redes neurais convolucionais mais profundas, enquanto a *Tanh* e a *sigmoide* são mais adequadas para problemas de classificação binária ou multi-classe.

O *pooling* é uma operação que tem como objetivo reduzir o tamanho da imagem e diminuir a carga computacional da rede, através da redução do número de parâmetros e da introdução de invariância nas translações na entrada (LECUN et al., 1998). Já as camadas totalmente conectadas integram as informações de todas as camadas anteriores e geram a saída final da rede (GOODFELLOW et al., 2016).

É importante destacar que as operações realizadas em cada camada podem variar de acordo com a arquitetura da rede neural e a tarefa a ser realizada. Por exemplo, algumas arquiteturas podem adicionar operações como o *dropout* ou o *batch normalization* para melhorar o desempenho da rede em determinadas tarefas (SRIVASTAVA et al., 2014; IOFFE & SZEGEDY, 2015).

O processo de aprendizado das redes convolucionais é feito por meio do ajuste dos pesos das camadas convolucionais durante a fase de treinamento. De acordo com Goodfellow et al. (2016), tais camadas vão gradativamente se ajustando para detectar padrões específicos nas imagens de entrada, aprimorando suas capacidades de extrair características relevantes para as tarefas de classificação, segmentação ou detecção de objetos.

2.2.5 Redes Adversárias Generativas

Criada por Goodfellow et al em 2014, o modelo adversarial generativo (GAN) é um modelo arquitetural de redes neurais profundas compostas por duas redes convolucionais: uma geradora e outra discriminadora. O modelo consiste em um processo adversarial em que a rede geradora é colocada contra um adversário, mais especificamente um modelo discriminativo. Nesse processo, as redes sintetizam imagens por meio de sua estrutura.

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 retro propagação 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:

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

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:

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

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:

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

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. Na Quadro 1 é possível ver a demonstração de como ocorre o treinamento do modelo, utilizando $k = 1$:

Quadro 1: Modelo de algoritmo de Goodfellow et al, 2014.

1: **For** número de interação no treino **do**:

2: **For** k passos **do**:

3: Amostra do mini batch de m amostras de ruído $\{z^1, \dots, z^m\}$ na distribuição de $P_z(z)$

4: Amostra do mini batch de m exemplos $\{x^1, \dots, x^m\}$ da distribuição $P_{data}(x)$

5: Atualiza o discriminador ascendendo seu gradiente estocástico:

$$\nabla_{\theta_d} \frac{1}{m} \sum_{i=1}^m [\log D(x^i) + \log(1 - D(G(z^i)))]$$

6: Amostra do mini batch de m amostras de ruído $\{z^1, \dots, z^m\}$ da distribuição $P_z(z)$

7: Atualiza o gerador descendendo seu gradiente estocástico:

$$\nabla_{\theta_g} \frac{1}{m} \sum_{i=1}^m [\log(1 - D(G(z^i)))]$$

Fonte: GOODFELLOW et al, 2014.


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 Figura 12 apresenta a arquitetura da GAN.

Figura 12: 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.

Como exemplo é possível mencionar as criações feitas por Mextz et al (2016) de múltiplos quartos (Figura 13).

Figura 33: Criação de quartos a partir das GANs



Fonte: Mextz et al (2016)

As imagens de quartos criados por Mextz et al (2016) apresentam uma grande diversidade em termos de decoração, *layout* e estilo arquitetônico. Cada quarto tem uma combinação única de cores, móveis, objetos decorativos e iluminação, o que resulta em uma aparência distinta e personalizada para cada um deles.

Essa diversidade de estilos e *layouts* torna a criação de quartos automatizada uma ferramenta muito útil em áreas como *design* de interiores, arquitetura, *marketing* imobiliário, entretenimento digital, artes etc. Com essa tecnologia, é possível gerar uma ampla gama de quartos personalizados em pouco tempo, economizando tempo e recursos na produção de conteúdo visual.

Outro exemplo são as criações feitas por Kaust et al (2019). de múltiplos rostos humanos (Figura 14).

Figura 44: Criação de rostos humanos a partir das GANs



Fonte: Kaust et al (2019)

As imagens de rostos criados por Kaust et al (2019) usando as GANs apresentam uma diversidade em termos de características faciais. Nelas existem variações no formato do rosto, tamanho de olhos, nariz, boca e cabelo. Há variações como sombras, luzes mais fortes ou mais fracas em diferentes partes do rosto, o que pode afetar a aparência geral da imagem, assim como a variação da cor.

A partir dessa diversidade de criações, é possível pensar que as GANs podem ser ferramentas poderosas na criação de personagens em jogos e animações, pois elas são capazes de gerar uma grande diversidade de características faciais e expressões em rostos sintéticos. Isso permite a criação de personagens mais realistas e cativantes. Além disso, é possível pensar na utilização dessa tecnologia para criar ativos visuais (*assets*) para jogos que são elementos gráficos fundamentais para o jogo como personagens.

3 PROCEDIMENTOS METODOLÓGICOS

A presente pesquisa tem como objetivo estudar o potencial do modelo conceitual de redes adversárias generativas na construção de *assets* visuais em 2D para artistas de *games*. Para tanto foi adotada uma abordagem de pesquisa indutiva, com a utilização de um estudo de caso (GIL, 2022) e análise de dados por meio do método de trabalho denominado de observação direta (DRESCH et al., 2020) e entrevistas estruturadas (KAUARK et al., 2010; GIL, 2022) realizadas a artistas atuantes nos atuais cenários dos *games* para coletar dados e validar os resultados.

A escolha da abordagem indutiva se justifica pela natureza do estudo, que busca compreender os processos e fenômenos envolvidos na construção de *assets* visuais em 2D para *games*. Nessa abordagem, o fenômeno empírico é observado em suas relações e depois são construídas as conjecturas que contribuem tanto para a solução do problema, como para a fundamentação de novas teorias (DRESCH et al., 2020). Desse modo, o método científico adotado foi o indutivo por possibilitar a formulação de inferências a respeito do que está sendo pesquisado e a solução da problemática.

O 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).

Segundo (DRESCH et al., 2020), o método de trabalho observação direta

permite que o investigador identifique certas características do fenômeno ou sistema em estudo que muitas vezes passam despercebidas pelos indivíduos que fazem parte desse sistema. Portanto, essa técnica é mais adequada para alguns estudos de que a própria entrevista ou questionário em geral. No entanto, para ter validade científica, a observação deve ser precedida de um elaborado planejamento. Pode ser feita de forma estruturada ou não, individualmente ou por uma equipe e num ambiente real ou controlado em laboratório (DRESCH et al., 2020, p. 35).

O planejamento observacional dos resultados foi feito para observar os parâmetros de pigmentação (cor) e formato.

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).

As entrevistas estruturadas (KAUARK et al., 2010; GIL, 2022) com os artistas de *games* foram realizadas com perguntas previamente definidas e de forma sistemática. O entrevistador também utilizou recursos remotos para obter respostas às indagações. Neste caso o entrevistador pode realizar a entrevista por telefone, pela internet ou por meio de outras tecnologias. Para tanto, optou-se pela internet e foi utilizado o google formulário como suporte.

A metodologia é composta de uma sequência lógica de cinco 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 *games*.

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 da arte digital dos *games* ao longo do tempo até a indústria atual, 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 consultados referências bibliográficas que nortearam a pesquisa: Rogers (2013), Bobany (2008), Parish, (2018), Williams (2017), Wolf (2012), Lapetino (2016), Souza e Rocha (2005), willrich (2000), Luz (2021), Goodfellow et al, (2014), Salgado (2020), Duarte (2012), Lieser (2009), Russell e Norving (1995), Mextz et al (2016), Kaust et al (2019), Caccia (2018), Kuntal (2017), Frutuoso e Bedrgal (2022), Nguyen (2021), Bittencourt (1998), Jo (2021), Schwa (2019), Willrich (2000), Anderson e Bavelier (2011).

Na terceira etapa foi realizado o planejamento do estudo de caso (DRESCH et al., 2020). Nela foi definido o modelo conceitual de redes (o modelo escolhido foi o de Goodfellow et al. (2014)² 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

² O código do modelo conceitual adotado produzido por Goodfellow et al. (2014) pode ser acessado por meio do URL: <https://github.com/goodfeli/adversarial> >. Acesso em 09 abr. 2023.

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 código³ em Node.js que é um *framework* para a utilização de linguagem Javascript. Essas imagens são coloridas e foram redimensionadas⁴ para serem usadas nos testes do modelo conceitual de redes adversárias generativas, nas dimensões de 32 x 32 pixels. Os *assets* visuais em 2D utilizados no treinamento são mostrados na Figura 15.

Figura 55: *Assets* visuais em 2D do Axie Infinity



Fonte: produzida pelo autor a partir de *assets* do Axie Infinity

Na quarta etapa da pesquisa foi realizada a condução do teste (DRESCH et al., 2020). Os ativos visuais utilizados no treinamento, num total de 15.000 *assets* coloridos, tinham dimensões de 32 x 32 pixels. O algoritmo de otimização utilizado foi o Sigmoide⁵ o tamanho do lote (batch) utilizado foi de 100. Para o teste, foram usadas duas camadas de redes

³ Parte do código utilizado para baixar as imagens pode ser acessada por meio do URL: <<https://github.com/JeffersonValentim1/Image-download-node/tree/main>>. Acesso em 23 mar. 2023. Estes códigos também se encontram no Anexo I.

⁴ As imagens foram redimensionadas por meio de código. Esse código pode ser acessado por meio do URL: <<https://github.com/JeffersonValentim1/img-convert/tree/main>>. Acesso em 09 abr. 2023.

⁵ Sigmoide é uma função matemática que transforma um número em uma probabilidade entre 0 e 1. É comumente usada em *machine learning* para classificação binária.

convolucionais⁶ ambas com 64 filtros. O tempo de geração dos *assets* foi de 4 horas e foram utilizadas um total de aproximação de 300 épocas⁷.

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.

A cor é um elemento utilizado para transmitir significados específicos de itens, roupas e personagens nos jogos, assim como é um elemento que desempenha um papel crítico no reconhecimento de objetos e pode fornecer sugestão de reconhecimento para formas de objetos em imagens (MEPELI & BEHRMANN, 1997; HAGEN et al, 2014; TEICHMANN et al, 2020). Portanto, analisar a cor das imagens geradas pela GAN é essencial para avaliar a qualidade e fidelidade das imagens geradas.

O formato é significativo pois trata-se de um aspecto fundamental da composição de ativos artísticos (ROGERS, 2013; BOBANY, 2008; WILLIAMS, 2017). Ele influencia a legibilidade, o equilíbrio e a coesão da imagem como um todo. Analisar o formato dos *assets* gerados pela GAN permite avaliar a capacidade do modelo em aprender e reproduzir as formas de objetos presentes nas imagens de treinamento. Para isso, selecionou-se uma amostra de 60 ativos visuais que foi comparada manualmente com as imagens geradas pelo modelo conceitual de redes adversárias generativas. Essa análise teve o objetivo de comparar a estrutura básica dos *assets* gerados com os pré-existentes, procurando possíveis similaridades, singularidades e deformações que venham a ocorrer nos *assets* gerados e à comparação das cores. A quinta etapa da metodologia foi a aplicação de um formulário (Google Formulário) para artistas que estejam atuando no mercado de jogos. A amostra consistiu de 50 artistas que possuem de 2 a 10 anos de experiência. Para isso, foi feita uma busca por artistas utilizando o LinkedIn (LINKEDIN, 2023) e aplicado o formulário que versa sobre o uso de GANs na criação de *assets* em 2D para *games*. Por fim, uma avaliação preliminar das respostas foi realizada.

⁶ Redes convolucionais são um tipo de rede neural profunda usada em reconhecimento de imagens, processamento de linguagem natural e outras aplicações que envolvem dados com estrutura espacial. Elas utilizam filtros convolucionais para extrair características dos dados e reduzir sua dimensionalidade, o que ajuda a melhorar a precisão e a eficiência do modelo.

⁷ Cada época é composta por várias iterações, em que o modelo atualiza seus pesos com base no erro de discriminação e no erro de reconstrução dos dados de saída. À medida que o modelo é treinado por mais épocas, espera-se que ele melhore sua capacidade de gerar dados de saída mais realistas e com melhor qualidade.

4 O ESTUDO DE CASO UTILIZANDO ATIVOS ARTÍSTICOS DO AXIE INFINITY

Neste capítulo é apresentado um estudo de caso que utiliza os *assets* visuais do jogo *Axie Infinity* como base de dados para treinar *Generative Adversarial Networks* (GANs). O objetivo é explorar a capacidade das GANs em gerar novos *assets* visuais a partir dos dados existentes.

O procedimento de coleta de dados é apresentado na seção 4.1, o processo de criação de personagens é descrito na seção 4.2 e a análise dos resultados é feita na seção 4.3.

4.1 O Procedimento de Coleta de Dados

Antes de iniciarmos o estudo de caso, é importante entender o contexto e a escolha dos dados utilizados na pesquisa. O *Axie Infinity* é um jogo que permite a criação, compra e venda de ativos artísticos digitais, como os *Axies*. Para nosso estudo, decidimos focar nos ativos 2D de personagens criados para o *Axie Infinity*, já que esses ativos são amplamente utilizados no jogo e apresentam um grande variedade e potencial para expansão e diversificação, além de serem colecionados por diversos jogadores.

Para gerar novos ativos 2D para o *Axie Infinity*, utilizamos uma IA do tipo GAN treinada especificamente para esta tarefa. Escolhemos este modelo de IA porque ele é capaz de aprender a partir de exemplos, gerando novas imagens que são semelhantes, mas não idênticas aos dados de treinamento. Para o treinamento da IA, utilizamos uma base de dados de imagens de *Axies*, bem como outras imagens relacionadas ao tema do jogo que se configuram como ruídos conforme a arquitetura do modelo.

A coleta de dados para o treinamento ocorreu de duas formas: manual e automática. Em um primeiro momento, os dados foram coletados diretamente do *Axie Infinity* durante um período de 7 meses. Em um segundo momento, a fim de aumentar a base de dados, foi utilizado um código⁸ em Node.js para coletar os dados. Node.js é uma plataforma de desenvolvimento de aplicações em JavaScript que utiliza o motor V8 do Google Chrome para executar código do lado do servidor. Com Node.js, é possível desenvolver aplicações escaláveis, rápidas e eficientes.

⁸ Os códigos utilizados para baixar as imagens pode ser acessado por meio do URL: <<https://github.com/JeffersonValentim1/img-download>>. Acesso em 09 abr. 2023.

Os personagens coletados eram coloridos e em diferentes formatos. Eles foram redimensionados para o tamanho de 32 x 32 *pixels* e numerados. A quantidade de ativos artísticos coletados foi de 15.000.

A escolha desses dados foi fundamental para o sucesso do estudo de caso, pois permitiu que a IA do tipo GAN fosse treinada com exemplos relevantes e representativos do universo do *Axie Infinity*. Além disso, essa base de dados permitiu que a IA aprendesse a criar ativos artísticos 2D que são visualmente semelhantes aos *Axies* já existentes, mas com novas variações e características.

4.2 A criação dos personagens

Para testar o potencial da utilização de GANs na criação de personagens do *Axie Infinity*, o modelo de GANs foi treinado utilizando 15.000 imagens de *Axies*, com 32 x 32 *pixels*. No teste foi utilizando o algoritmo de treinamento adversarial da GAN⁹.

O tempo de duração do treinamento levou 5 semanas com intermitências. Isso se deve à grande quantidade de imagens de treinamento (15.000), ao tamanho do batch (100) e ao número de épocas de treinamento (aproximadamente 300). Ademais, a dimensão dos *assets* coloridos também influenciou no tempo de treinamento, já que imagens maiores geralmente exigiriam mais poder de processamento. A utilização dos *assets* em 32 x 32 *pixels* coloridos proporcionaram maior velocidade no processo. Uma vez treinado, o modelo de GANs foi capaz de gerar/imprimir novos *assets* em um tempo relativamente curto, de cerca de 4 horas. A impressão foi setada para 10 *assets*.


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

⁹ O código do modelo conceitual adotado produzido por Goodfellow et al. (2014) pode ser acessado por meio do URL: <https://github.com/goodfeli/adversarial> >. Acesso em 09 abr. 2023.

únicos e diversificados pode ser visto na Figura 16 onde é apresentada a estrutura de funcionamento do modelo.

É importante mencionar que, devido a pandemia do *Sars-CoV-2* e o isolamento social, diversas limitações foram impostas. A limitação computacional implicou na utilização reduzida do modelo, ou seja, os parâmetros escolhidos foram os que puderam ser utilizados em um computador doméstico e em um ambiente domiciliar devido ao isolamento. Nesse contexto, o treinamento ocorreu com os recursos disponíveis para o teste em ambiente isolado.

Figura 6: Representação Gráfica do Processo de Criação de Personagens



Fonte: produzido 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*.

Em seguida a rede geradora volta a funcionar com novos ajustes. Esse novo funcionamento e início de círculo é denominado de época. E a cada época, as imagens serão criadas de formas diversificadas. É cada vez mais um sentido estético e significativo próximo das imagens reais do jogo *Axie Infinity*.

O fenômeno 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.

Assim, partindo do modelo de algoritmo proposto, foi feito um teste da rede usando os *assets* visuais 2D coletados do *Axie Infinity*. Algumas imagens podem ser vistas na Figura 17.

Figura 7: *Assets* visuais 2D do *Axie Infinity*



Fonte: Produzido pelo autor a partir dos *assets* coletados

Esses *assets* são modelos de personagens utilizados em *Axie Infinity* que 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.

Nesse contexto, a outra rede criou a partir de ruídos diversos modelos de *assets* 2D. Esses modelos foram aperfeiçoados com o passar das épocas e analisados pelo discriminador.

4.3 Análise dos Resultados

Nesta seção apresentaremos os resultados práticos da utilização do modelo de IA GAN para criar *assets* para o *game Axie Infinity*. 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 a Figura 18 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.


Figura 8: Resultados variados



Fonte: produzido 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 2).

Quadro 2: 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* (Quadro 3).

Quadro 3: Exemplo pontual de *asset* original e *assets* gerados

Assets originais	Novos Assets gerado pelas GANs
	

Fonte: produzido pelo autor

No Quadro 3 é possível perceber que o modelo de GANs criou *assets* com características exclusivas, tais como novos olhos, bocas, chapéus e rabos. Através da utilização de técnicas de aprendizado profundo, esse 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 redes adversárias generativas apresenta capacidade para gerar novos *assets* visuais a partir dos dados existentes. Isto sugere que os artistas podem utilizar este modelo para produzir *assets*.

4.4 Validação Preliminar

Nesta seção vamos explorar a percepção dos artistas de *games* sobre o potencial das GANs na criação de *assets* em 2D para artistas de *games*. Para tanto realizamos entrevistas preliminares com artistas que trabalham na criação de *assets* em 2D para jogos eletrônicos. Nosso objetivo foi avaliar se os resultados gerados por meio do uso de GANs são válidos e se os artistas acreditam que essa tecnologia pode ser útil para otimizar e agilizar o processo de criação de *assets* em 2D.

A amostra contempla artistas que já atuam no mercado de jogos e que possuem experiência de 2 a 10 anos na criação de *assets* em 2D para *games*. A escolha desses indivíduos se justifica pelo fato de que eles possuem um conhecimento prático sobre o processo de criação de *assets* em 2D. Utilizamos o modelo de entrevista estruturada (KAUARK et al., 2010; GIL, 2022), pois permite que as questões sejam padronizadas e que as respostas dos entrevistados possam ser comparadas de maneira mais objetiva. As entrevistas foram realizadas por meio do *Google Formulários*.

Os 50 (cinquenta) artistas selecionados para a entrevista têm idade entre 25 e 40 anos. A entrevista ficou disponível *on-line* por um período de 30 dias o que possibilitou ao entrevistado refletir sobre suas respostas e pesquisar mais sobre o tema, se necessário. As imagens mostradas aos entrevistados foram as disponíveis no Quadro 2

As perguntas foram elaboradas com o objetivo de avaliar o potencial das GANs na produção de *assets* para artistas de *games*, e de averiguar a possibilidade de uma integração das GANs na rotina de trabalho dos artistas. O Quadro 3 apresenta as perguntas realizadas.

Quadro 3: Perguntas realizadas

Perguntas da Entrevista
1. Você já ouviu falar sobre Inteligência Artificial criando artes para jogos?
2. Você acredita que modelos de inteligências artificiais como as Redes Adversárias Generativas podem ser úteis na criação de <i>assets</i> visuais em 2D para jogos?
3. As imagens sintéticas geradas pela GAN possuem estrutura, forma e cor que as equipara com as imagens reais para serem utilizadas em um game?
4. Você acredita que o uso de GANs pode aumentar a velocidade de criação de <i>assets</i> em 2D para <i>games</i> ?
5. Você acha que o uso das GANs pode diminuir a necessidade de um artista de criar <i>assets</i> manualmente?
6. Os <i>assets</i> gerados pelo modelo podem ser utilizados para inspirar novos <i>assets</i> sintéticos?
7. Quanto tempo em média você leva para produzir <i>assets</i> visuais em 2D, como personagens, itens e objetos para jogos eletrônicos?


Fonte: produzido pelo autor

As seis primeiras perguntas possuem respostas binárias (sim ou não) e pretendem capturar as expectativas dos profissionais da área em relação ao uso das GANs. Todas as trezentas respostas foram positivas o que sugere que as perspectivas destes profissionais são otimistas.

Em linhas gerais, as respostas positivas dos entrevistados sugerem que o uso de Inteligência Artificial na criação de arte para jogos é um tema conhecido (indica que os profissionais da área estão cientes das possibilidades e limitações dessa tecnologia); que há uma aceitação considerável das tecnologias de IA na criação de ativos visuais para jogos eletrônicos (indica um potencial de mercado para a pesquisa e desenvolvimento de tecnologias de geração de imagens sintéticas para jogos eletrônicos); que todos os participantes acreditam que os novos *assets* visuais em 2D gerados pelas GANs são equiparáveis aos reais (indica que as imagens geradas pelas GANs atingem o potencial de serem chamadas de *assets*); que a utilização de tecnologias de IA pode ser vista como uma solução para otimizar o processo de criação de artes para *games* (sinaliza um potencial mercado para o desenvolvimento de novas tecnologias de geração de imagens sintéticas para jogos e aceitação do artista no uso desse recurso); e que a tecnologia tem potencial para inspirar os artistas na criação de novos *assets* sintéticos (implica que os *assets* gerados por GANs podem servir como ponto de partida para artistas que buscam criar *assets* para seus jogos, além de fornecer referências visuais que podem ser usadas para criar ou ajustar *assets* existentes).

O Quadro 4 apresenta os resultados da questão de número 7. As porcentagens indicam o número de respostas marcadas pelos artistas entrevistados, totalizando 100% que equivale a 50 respostas.

Quadro 4: Tempo para a Produção de *Assets*



Fonte: Produzido pelo autor

A maioria, correspondente a 44%, indicou que leva de 12 horas a 24 horas para produzir *assets* visuais; 30% dos entrevistados relataram que levam de 6 horas a 12 horas;

22% dos entrevistados indicaram que levam mais de 24 horas para produzir ativos visuais. Depreende-se que 98% dos entrevistados levam mais de 4 horas para produção de *assets*, enquanto apenas 2% gastam de 4 a 6 horas. Nenhum dos entrevistados levou menos de 4 horas para produzir ativos visuais. Esses resultados mostram que a produção de *assets* visuais em 2D para jogos eletrônicos pode levar um tempo considerável. Isto pode ter implicações no processo de desenvolvimento e na necessidade de se buscarem soluções alternativas para agilizar essa produção. Ademais, vai ao encontro dos resultados da questão 4 pois todos os 50 entrevistados concordam que o uso de GANs pode aumentar a velocidade de criação de *assets* em 2D para *games*, ou seja, ao utilizar GANs os artistas de jogos podem acelerar o processo de produção de *assets* e, consequentemente, lançar jogos mais rapidamente (o uso de GANs permite que os desenvolvedores criem mais *assets* em um período menor, o que pode ser útil em casos de cronogramas apertados). No entanto, é importante lembrar que a qualidade dos *assets* gerados por GANs pode variar, dependendo da qualidade do modelo e da quantidade de dados usados para treiná-lo.

5 CONSIDERAÇÕES FINAIS

A presente dissertação teve como objetivo explorar o potencial do modelo conceitual de redes adversárias generativas na construção de *assets* em 2D para artistas de *games*. Fez-se um percurso teórico de conceitos envolvendo arte digital, a produção de artes para *games*, a Inteligência Artificial (aprendizado de máquina, redes neurais artificiais, aprendizado profundo, redes convulsionais e redes adversárias generativas). Ademais, foram realizados um estudo de caso e entrevistas com artistas atuantes no atual cenário de *games*.

A evolução do mercado de *games* aumentou a demanda por artistas voltados para o desenvolvimento de *games*. Com o *upgrade* dos jogos e suas tecnologias, a demanda pode se intensificar. Isso implica na participação de mais pessoas na criação de artes personalizadas para *games*, assim como na necessidade de elaboração de ferramentas mais eficientes que permitam a criação de novas formas de expressões artísticas, diversificadas e singulares. Por exemplo, a possibilidade de utilizar redes generativas adversárias na criação de imagens para *games*. Essa tecnologia, por consistir num tipo de algoritmo de aprendizado de máquina que é capaz de gerar imagens a partir de um conjunto de dados de entrada, pode ser utilizada para gerar *assets* em duas dimensões. Realizamos uma prova de conceito através de um estudo de caso realizado com os *assets* do game *Axel Infinity*.

A partir do estudo de caso foi possível perceber que o modelo tem um potencial de criar imagens com traços semelhantes às usadas no treinamento. Esse fenômeno possibilita ao modelo criar 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.

Além do mais, em análise ao tempo médio de produção de *assets* visuais em 2D para *games* que pode variar significativamente, como indicado pelos resultados das entrevistas, o modelo tem o potencial de auxiliar o artista no que tange a aceleração de produção, pois conforme os entrevistados, uns levam 12 e 24 horas para produzir, enquanto para outros levam de 6 a 12 horas ou mais de 24 horas. Esses tempos de produção podem ter um impacto

significativo no processo de desenvolvimento de *games*, já que a criação de *assets* visuais é uma parte importante e que exige um processo de trabalho intenso.

Ademais, considerando que o modelo leva cerca de 4 horas para criar um *asset*, pode-se argumentar que o uso de ferramentas de inteligência artificial pode ser uma ferramenta interessante para acelerar o processo de produção de *assets*. Com a ajuda das GANS, é possível criar *assets* visuais em tempo mais reduzido.

É importante ressaltar que, apesar de promissora, a utilização das GANs na condição de ferramentas para produção de *assets* visuais em 2D para jogos eletrônicos enfrenta desafios, sendo a grande quantidade de imagens para treinamento dos algoritmos um dos principais desafios.

O modelo de criação de *assets* visuais com GANs demonstrou potencial para gerar ativos em tempo menor que o dos desenvolvedores entrevistados. Isto pode ter um impacto significativo no desenvolvimento de *games*. Assim, é possível inferir que o modelo tem potencial para criar *assets* visuais em 2D para artistas de *games*.

Esse resultado é significativo para a área de estudo que se concentra na utilização de GANs para produzir obras de arte. Pois tendo os autores, como Volz et al (2018) trabalhado a questão da criação de níveis para jogo, Sousa (2019) a criação de terrenos e paisagens, Hald et al (2020) na criação de fases e itens para o game e Oliveira (2021) afirmando que as GANs podem inspirar artistas.

Algumas limitações impostas à pesquisa, realizada no período da pandemia do SARS-CoV-2, foram as seguintes: o acesso aos dados residentes em instituições acadêmicas e do mercado, bem como às empresas de jogos que estavam funcionando em *home office*.

A título de continuidade desta dissertação, recomendamos as seguintes cinco propostas de trabalhos futuros em relação ao uso de redes adversárias:

Implementar o modelo de redes adversárias generativas a programas de edição de imagem como programas *open source* que possam comportar o código do modelo. Isto possibilitaria o artista produzir imagens realistas de forma automatizada diretamente em uma interface de desenho.

Desenvolver uma ferramenta baseada em redes adversárias que permita aos desenvolvedores de jogos personalizar os *assets* gerados de acordo com suas necessidades específicas, permitindo que eles escolham o estilo de arte ou os elementos que desejam incluir em um *sprite* gerado automaticamente. Isso poderia incluir a criação de uma interface de usuário amigável para facilitar o uso da ferramenta pelos desenvolvedores.

Desenvolver uma ferramenta que se conecte com os *games* já criados e os forneça *assets* novos para serem utilizados nos *games* em instantaneidade. Assim criando APIs de *streamer* de arte para jogos.

Utilizar GANs para a geração de paisagens e cenários aleatórios em jogos de mundo aberto, permitindo que os jogadores explorem um ambiente sempre novo e surpreendente em cada partida.

Criar um sistema de animação de personagens em 2D utilizando GANs para gerar animações fluidas e realistas para personagens em jogos.

Por fim, ao analisar os resultados obtidos através do estudo de caso e das entrevistas realizadas, foi possível constatar de forma direta que o modelo desenvolvido apresenta a capacidade de gerar novos *assets* visuais a partir de dados existentes. Isso sugere que o modelo possui potencial para criar *assets* visuais em 2D e que podem ser utilizados por artistas em *games*, ou ainda servir como fonte de inspiração para a criação de novos *assets* visuais, como indicado pela hipótese inicial da pesquisa. Essa descoberta é de grande importância para o desenvolvimento de jogos eletrônicos, uma vez que o processo de criação de *assets* visuais pode ser acelerado com o auxílio do modelo, possibilitando um aumento na produtividade e na criatividade dos artistas de *games* atuantes no atual cenário.

REFERÊNCIAS BIBLIOGRÁFICAS

ALPAYDIN, E. **Introduction to machine learning**. 3. ed. MIT Press, 2020.

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

BATISTA, S. L. M.; QUINTÃO, L. P.; LIMA, B. M. S.; CAMPOS, D. C. L.; BATISTA, S. J. T. Um estudo sobre a história dos jogos eletrônicos. **Revista eletrônica da Faculdade Metodista Granbery**, São Paulo, n.3, p. 1-24, jul/dez, 2007. Disponível em: <l1nq.com/vo0Qa>. Acesso em: 24 fev. de 2023.

BENGIO, Y.; COURVILLE, A.; VINCENT, P. Representation learning: a review and new perspectives. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 35, n. 8, p. 1798-1828, 2013. Disponível em: <<https://ieeexplore.ieee.org/document/6526459>>. Acesso em: 01 mar. 2023.

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.

BOBANY, A. **Vídeo game arte**. Rio de Janeiro: Novas Ideais, 2008.

BRITANNICA. Electronic game. **Encyclopedia Britannica**, 1 de nov. 2022. Disponível em: <<https://www.britannica.com/topic/electronic-game>>. Acesso em: 05 de mar. de 2023.

BRITO, A. Coleção com 18 árvores gratuitas para Unreal Engine. **Allan Brito**, Recife, 1 de dezembro de 2016. Disponível em: <<https://www.allanbrito.com/2016/12/01/colecao-com-18-arvores-gratuitas-para-unreal-engine>>. Acesso em: 3 jun. 2022.

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*. **Acrromoth**, 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.; OBRIEN, 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.

ELGAMMAL, A.; LIU, B.; ELHOSEINY, M.; MAZZONE, M. CAN: Creative adversarial networks, generating "art" by learning about styles and deviating from style norms. Ithaca: **ArXiv**, 21 jun. 2017. Disponível em: <<https://arxiv.org/abs/1706.07068>>. Acesso em: 04 mar. 2022.

EMBE, C. Z.; HUSSAIN, H. An edutainment framework implementation case study. In: CARTELLI, A.; PALMA, M. **Encyclopedia of information communication technology**. 2º ed. EUA: Igi Global, 2008. pp. 202-208.

FRUTUOSO, Hortevan M.; BEDREGAL, Benjamin R. C. Processamento de linguagem natural controlada utilizando uma máquina de moore. In: Encontro nacional de inteligência artificial e computacional (ENIAC), 15., 2018, São Paulo. **Anais ENIAC**. Porto Alegre: Sociedade Brasileira de Computação, 2018. p. 13-24.

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.

GATYS, L. A.; ECKER, A. S.; BETHGE, M. A neural algorithm of artistic style. Ithaca: **ArXiv**, 02 set. 2015. Disponível em: <<https://arxiv.org/abs/1508.06576>> Acesso em 04 mar. 2022.

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

GLOT, X.; BORDES, A.; BENGIO, Y. Deep sparse rectifier neurais networks. In: International conference on artificial intelligence and statistics, 14., 2011, Fort Lauderdale, Florida. **Anais da Décima Quarta Conferência Internacional sobre Inteligência Artificial e Estatística**: PMLR, 2011. p. 315-323. Disponível em: <<http://proceedings.mlr.press/v15/glot11a.html>>. Acesso em: 05 mar. 2023.

GOODFELLOW, J. I.; ABADIE, P. J.; MIRZA, M.; XU, B.; FARLEY, W. D.; ORZAI, 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.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**. Cambridge: MIT Press, 2016. Disponível em: <<https://www.deeplearningbook.org/>>. Acesso em: 01 mar. 2023.

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/>>. Acesso em: 3 de jun. de 2022.

HAGEN, S.; VOUNG, Q. C.; SCOTT, S. L.; CURRAN, T.; TANAKA, W. J. The role of color in expert object recognition. **Journal of Vision**, [s. l.], v. 14, n. 09 August 2014, Vol.14, n. 9. pp. 1-13. Disponível em <<https://jov.arvojournals.org/article.aspx?articleid=2194091>>. Acesso em: 18 fev. 2023.

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

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

HAYS. 11 empregos mais demandados em TI para 2022, 2022. **HAYS**: Working for tomorrow, EUA. Disponível em: <<https://www.hays.com.br/conteudo/blog-dicas-de-carreira/insights/11-empregos-mais-demandados-em-ti-para-2022>>. Acesso em: 20 de jul. de 2022.

HERZ, J. C. **Joystick nation**: how videogames ate our quarters, won our hearts, and rewired our minds. Boston: Little & Brown. 1997.

HUIZINGA, J. **Homo ludens**: o jogo como elemento da cultura. São Paulo: Perspectiva, 2019.

HALD, A.; HANSEN, S. J.; KRISTENSEN, J.; BURELLI, P. Generating game levels with GANs. In: FDG '20: Proceedings of the 15th international conference on the foundations of digital games, 99, 2020, New York. Anais da **FDG '20: proceedings of the 15th international conference on the foundations of digital games**: Association for Computing Machinery, 2020. p. 1-9. Disponível em: <<https://dl.acm.org/doi/10.1145/3402942.3409601>>. Acesso em: 05 mar. 2023.

IOFFE, S.; SZEGEDY, C. Batch normalization: accelerating deep network training by reducing internal covariate shift. In: Internacional conference on machine learning, 32., 2015, Lille, France. **Anais da 32 Conferência Internacional de aprendizado de máquina**: PMLR, 2015. p. 448-456. Disponível em: <<http://proceedings.mlr.press/v37/ioffe15.html>>. Acesso em: 05 mar. 2023.

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

JORDAN, M. I.; MITCHELL, T. M. Machine learning: trends, perspectives, and prospects. **Science**, v. 349, n. 6245, p. 255-260, 2015. Disponível em: <<https://science.sciencemag.org/content/349/6245/255.full>>. Acesso em: 1 mar. 2023.

KAUARK, F. S.; MANHÃES, F. C.; MEDEIROS, C. H. **Metodologia da pesquisa**: guia prático. Itabuna: Via Litterarum, 2010.

KAUST, R. A.; KAUST, Y. Q.; KAUST, P.W.; Image2StyleGAN: how to embed images into the styleGAN latent space. **ArXiv**, Ithaca, jan. 2019.

KWAK, J. G.; KO, H. unsupervised generation and synthesis of facial images via an auto-encoder-based deep generative adversarial network. **Applied sciences**, v. 10, n. 6, p. 1995, 2020.

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.

LAPETINO, T. **Art of atari limited deluxe edition**. EUA: Dynamite Entertainment. 2016.

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.

LEMOES, 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.

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

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.

MCCARTHY, J. **What is artificial intelligence**. Stanford: Stanford University, 2004. Disponível em: <<http://www.fredbf.com/disciplinas/unibrattec/dsi/whatisai.pdf>>. Acesso em: 27 abr. 2021.

MCGINNIS, D. What is the fourth industrial revolution. **Sales Force**, EUA, 02 fev. 2023 Disponível em: <<https://www.salesforce.com/blog/what-is-the-fourth-industrial-revolution-4ir/>>. Acesso em: 16 fev. 2023.

MENDONÇA, F. C. I. Redes neurais convulsioneiras 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.

MEPELI, D.; BEHRMANN, M. The role of color in object recognition: Evidence from visual agnosia. **Neurocase**. USA, v. 3, pp. 237-247, jul. 1997. Disponível em: <<https://www.cmu.edu/dietrich/behrmannlab/Publications/MapelliBehrmann2.pdf>>. Acesso em: 18 fev. 2023.

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

MUELLER, J. P.; MASSARON, L. **Machine learning for dummies**. New Jersey: John Wiley & Sons, 2021.

MCGINNIS, D. What Is the fourth industrial revolution. **SalesForce**, EUA, 02 fev. 2023 Disponível em: <<https://www.salesforce.com/blog/what-is-the-fourth-industrial-revolution-4ir/>>. Acesso em: 16 fev. 2023.

MURPHY, M.; WRITER, C. The fourth industrial revolution: how automation and AI will impact manufacturing. **Zedesk**, EUA, 12 out. 2022. Disponível em: <<https://www.zendesk.com.br/blog/fourth-industrial-revolution/#georedirect>>. Acesso em: 16 fev. 2023.

NGUYEN, M. H. T. **Fundamentals of 2D game srt**. Oklahoma: Spring, 2021.

NOAN, M.G. **Behance**, 2022. Disponível em: <<https://www.behance.net/manoloide>>. Acesso em: 13 fev. 2023.

OLIVEIRA, C. C. **Utilizando redes adversárias generativas (GANs) como agente de apoio à inspiração para artistas**. 2021. Trabalho de Conclusão de Curso (Bacharelado em Ciência da Computação) - Universidade Federal de Pernambuco, Recife, 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.

PARISH, J. The 16-bit era. In. R. Montfort & N. Bogost (Eds.), **The essential guide to game history**. Minneapolis: The MIT Press, 2018. p. 93-103.

PEÑA- BICKLEY, J. Generative Art. **Cognitive experience design**. 30 de jan. de 2021. Disponível em: <<https://cognitiveexperience.design/generative-art/>>. Acesso em: 17 de mar. 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.; TIAN, Y. 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. **Artificial intelligence**: A Modern Approach. New Jersey: Elsevier, 1995.

_____. **Inteligência artificial**. Rio de Janeiro: Elsevier, 2013.

SALGADO, L. A. Z. **Arte digital**. Curitiba: Intersaberes. 2020.

SAMUEL, A. L. Some studies in machine learning using the game of checkers. **IBM Journal of Research and Development**, v. 3, n. 3, p. 210-229, 1959. Disponível em: <<https://ieeexplore.ieee.org/document/5392560>>. Acesso em 21 fev. 2023.

SCHWAB, K. **A quarta revolução industrial**. São Paulo: Edipro. 2019.

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.

SOLOMON, R. Sun yuan and peng yu: can't help myself. **Collection Online**, New York, 2016. Disponível em: <<https://www.guggenheim.org/artwork/34812>>. Acesso em 21 fev. 2023.

SOUZA, M. V. O., ROCHA, V. M. **Um estudo sobre o desenvolvimento de jogos eletrônicos**. João Pessoa: Unipê, 2005.

SOUZA, T. L. **Procedural terrain generation through image completion using GANs**. 2019. Trabalho de Conclusão de Curso (Bacharelado em Ciência da Computação) – Universidade Federal do Rio Grande do Norte, Natal, 2019.

SRIVASTAVA, N.; HINTON, G.; KRIZHEVSKY, A.; SUTSKEVER, I.; SALAKHUTDINOV, R. Dropout: A simple way to prevent neural networks from overfitting. **Journal of Machine Learning Research**, v. 15, n. 1, p. 1929-1958, 2014. Disponível em: <<http://www.jmlr.org/papers/v15/srivastava14a.html>>. Acesso em: 05 mar. 2023.

SUTTON, R. S.; BARTO, A. G. **Reinforcement learning: An introduction**. MIT Press, 2018.

TEICHMANN, L.; QUEK, L. G.; ROBINSON, K. A.; GROOTSWAGERS, T.; CARLSON, A. T.; RICH, N. A. Influence of object-color knowledge on emerging object representations in the brain. **Journal of Neuroscience**. [s. l.], v 10, n.35, pp. 6779-6789. Disponível em: <<https://www.jneurosci.org/content/jneuro/40/35/6779.full.pdf>>. Acesso em: 18 fev. 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>. 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.

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 2021. Disponível em: <<https://periodicos.ufpb.br/ojs2/index.php/tematica/article/view/61184/34294>>. Acesso em 03 fev. 2023.

VOLZ, V.; SCHRUM, J.; LIU, J.; LUCAS, S.; SMITH, A.; RISI, S.; Evolving mario levels in the latent space of a deep convolutional generative adversarial network. **ArXiv**, 2 mai. 2018. Disponível em: <<https://arxiv.org/abs/1805.00728>>. Acesso em: 04 mar. 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.

WOLF, M. J. P. **Before the crash**: early video game history. Detroit: Wayne State University Press. 2012.

ANEXO I

Parte do código utilizado para baixar as imagens:

```
const axios = require('axios')
const fs = require('fs')
const timeout = 3000;
const sleep = (tempoDelayMilisegundos) =>
new Promise((onResolve) => setTimeout(onResolve, tempoDelayMilisegundos));

for (let index = 3264; index <= 18264; index++) {
  sleep(timeout);

  let imageUrls = `https://axiecdn.axieinfinity.com/axies/${index}/axie/axie-full-
transparent.png`

  axios({
    method: 'get',
    url: imageUrls,
    responseType: 'stream'
  }).then(Response => {
    sleep(timeout);
    Response.data.pipe(fs.createWriteStream(`image${index}.png`))
    sleep(timeout);

    console.log('image downloaded')
  })

  console.log(imageUrls)
  sleep(timeout);
}
```