

**GANs – REDES ADVERSARIAS GENERATIVAS: definições e aplicações*****GANs – GENERATIVE ADVERSARIAL NETWORKS: definitions and applications***

Julio Cesar Gomes - julio.zidane70@gmail.com  
Faculdade de Tecnologia de Taquaritinga (Fatec) – Taquaritinga – SP – Brasil

Diego Renan Bruno - diego\_renan\_bruno@hotmail.com  
Faculdade de Tecnologia de Taquaritinga (Fatec) – Taquaritinga – SP – Brasil

DOI: 10.31510/inf.v20i2.1800

Data de submissão: 06/09/2023

Data do aceite: 16/11/2023

Data da publicação: 20/12/2023

**RESUMO**

O uso de Redes Adversarias Generativas (*Generative Adversarial Networks – GAN*) para a descoberta e aprendizado de padrões em conjunto de dados vem trazendo inovação e mudança em diversas aplicações. Elas são modelos que usam duas redes neurais, uma geradora e outra discriminadora, para novos dados que se assemelham a dados originais. Elas aprendem a distribuição de probabilidade dos dados originais e competem entre si para gerar dados de alta qualidade e diversidade. Sua utilização com qualquer tipo de dado permite resultados eficazes nos mais diversos campos, seja da arte, do entretenimento, na análise de dado ou na medicina, sua evolução cresce a cada dia. Esta pesquisa tem por objetivo analisar a Rede Adversaria Generativa (GAN), seus conceitos e desafios em suas aplicações. A pesquisa utilizada foi a bibliográfica, explorando diversos trabalhos científicos acadêmicos. Seus resultados demonstram possibilidades de desenvolvimento das mais variadas ferramentas e aplicação em diversas áreas, tornando esta ferramenta um instrumento promissor de novas tecnologias generativas.

**Palavras-chave:** inteligência artificial; redes adversarias generativas; redes neurais.

**ABSTRACT**

The use of Generative Adversarial Networks - GAN - by discovery and learning standard in datasets wich will bring inovation and change in several applications. It's a models that uses two neural networks, one generator and one decrimantor, to create data that resembles the original data. They learn the distribution of probabilities of the original data and compete with each other to generate quality and diverse data. Their use with the same type of data allows efcate results in the most diverse fields, be it in art, in entertainment, in data analysis or in medicine, their evolution grows every day. This research aims to analyse the Generative Adversarial Network (GAN), its concept and challenges in its application. The research used went the bibliografic, exploring many academic scientific works. Their results see possibilities of

development of more various tools and application in areas diverse, making this tool a promissor instrument of new generative technologies.

**Palavras-chave:** artificial intelligence; generative adversarial networks; neural networks.

## 1 INTRODUÇÃO

Redes Adversárias Generativas (GANs) foi descrita de maneira brilhante por Yann LeCun, uma figura proeminente do *deep learning*, como a ideia mais inovadora que surgiu nos últimos 10 anos sobre *machine learning*.

GANs consiste em dois modelos, sendo um gerador e outro discriminador. Estes dois modelos são implementados de forma diferente através de redes neurais, através de um sistema que mapeia dados de um espaço para outro. O gerador tem a função de capturar a distribuição de exemplos verdadeiros de dados e gerar novos exemplos de dados. Já o discriminador faz a discriminação dos exemplos gerados dos exemplos verdadeiros buscando a maior precisão possível.

A otimização dos GANs termina em um ponto mínimo de sela do gerador, ou seja, o ponto de sela é o mínimo em relação ao gerador e o máximo em relação ao discriminador, buscando a otimização para atingir o equilíbrio de Nash. Desta forma, o gerador capta a distribuição real dos exemplos verdadeiros (GUI et al, 2015).

Reis (2019) escreve que as Redes Generativas Adversárias são o estado da arte em modelos generativos e são utilizadas para a geração de amostras com probabilidade complexa, como a geração de imagens. Elas possuem aplicações de contexto de séries temporais, como por exemplo, a modelagem do preço de ações, demonstrando a sua vantagem de que, uma vez treinado o modelo, a geração de amostra se torna demasiadamente barata do ponto de vista computacional.

E possível então utilizar uma GAN que, uma vez recebendo o histórico de uma série temporal de retornos seja capaz de gerar amostras provenientes da distribuição do próximo instante de tempo. Desta forma pode-se utilizar estas amostras na estimação do valor esperado e da matriz de covariância deste instante (REIS, 2019, p.2).

Redes adversária generativa (GANs) tem o objetivo de gerar novas instancias que estão na distribuição de probabilidade no qual deriva os treinamentos de dados e isso, é resultado do método de otimização competitiva entre as redes neurais geradora e discriminadora.

Tal derivação permite que as GANs sejam utilizadas na geração de qualquer tipo de dados, sendo eficaz em vários campos como: visão computacional, síntese de séries temporais,

segmentação semântica, edição de imagens simples, edição de imagens através de texto, processamento de linguagem natural, entre outras funcionalidades (LA TORRE, 2023).

As redes adversárias generativas (*Generative Adversarial Networks - GANs*) foram introduzidas em 2014 por (GOODFELLOW et al., 2014). Sua arquitetura ganhou diversos adeptos e, nos últimos anos, uma grande variedade de artigos e arquiteturas foram propostas baseadas nesse projeto original. Essas redes são classificadas como modelos generativos e, portanto, têm como objetivo descobrir e aprender automaticamente padrões de um determinado conjunto de dados, sendo capazes de gerar novos exemplos únicos que sejam indistinguíveis de amostras obtidas desse conjunto. Nesse tipo de tarefa, as GANs demonstraram rapidamente seu grande potencial (LEÃO; FIGUEIREDO, 2022, p.11).

A partir da criação das GANs, muitas descobertas e avanços foram feitos, permitindo uma rápida evolução nos resultados gerados, incidindo na melhoria da qualidade, principalmente quando a tarefa for na geração de imagens. Devido a essa evolução as GANs são usadas em diversas aplicações como: aumento na resolução de imagens, geração de imagens realistas, aumento de dados, tradução de texto em imagens, bem como tradução de imagens para imagens e várias outras aplicações (LEÃO; FIGUEIREDO, 2022).

As GANs estão sendo muito pesquisadas e reconhecidas como uma ferramenta revolucionária e com muitas possibilidades de uso. As GANs são o auge em modelos geradores e tem sido empregada na produção de amostras provenientes de várias distribuições de probabilidade complexas, inclusive na geração de imagens e na modelação de preço de ações.

O objetivo geral deste artigo é analisar o que é a Rede Generativa Adversária e seu funcionamento nos diversos usos como ferramenta generativa e os objetivos específicos foram:

- Analisar o processo de formação das GANs;
- Verificar o uso das GANs em diversas aplicações.

Assim, o presente artigo visa analisar a importância das Rede Generativas Adversarias como técnica poderosa na geração de dados sintéticos semelhantes aos dados reais e pretende responder a seguinte questão de pesquisa: “Qual a definição de Redes Adversarias Generativas e quais suas aplicações?”.

A finalidade deste artigo é informar aos leitores e pesquisadores sobre o funcionamento das Redes Adversarias Generativas e quais suas aplicações no uso e produção de conteúdo através da simulação de dados sem ter o desejo de encerrar o tópico, pelo contrário, o objetivo é estimular mais investigação sobre a questão devido à relevância deste instrumento para o desenvolvimento de mais pesquisa sobre o assunto devido á importância desta ferramenta na

geração de amostras vindas de distribuição de probabilidade complexa com custo computacional extremamente barato.

O método empregado é a pesquisa bibliográfica, por meio de uma pesquisa extensa e detalhada em livros, artigos, monografias, sites etc. O estudo bibliográfico é uma fonte inesgotável de informações, pois contribui para o aprimoramento intelectual e para a aquisição de conhecimento cultural.

O saber que o pesquisador obtém nas obras estudadas leva ao conhecimento, pois é fundamentado em procedimentos metodológicos como a leitura, seleção, memorização etc. que são a base para todas as demais pesquisas (FACHIN, 2007).

## 2 REDES NEURAIIS ARTIFICIAIS

Redes neurais artificiais são um modelo de computação não-algorítmica que foi modelada com base no funcionamento de redes neurais biológicas, apresentando uma abordagem conexionista, ou seja, uma abordagem que não exige a utilização de regras ou lógica previamente definidas.

Idealizado pelo psicólogo Frank Rosenblatt em seu artigo *The perceptron: A preceiving and Recognizing Automoton*, no ano de 1957, a reprodução artificial de neurônios foi definida como perceptron (MENDES, 2020).

... o formalismo matemático desse elemento está definido na função  $a$ .

$$y = entrada(\sum_t^N w_t x_t - \theta) (a)$$

$$\Delta y = y_o - y (b)$$

$$\frac{\partial E_n}{\partial w_{ji}} = \frac{\partial E_n}{\partial b_{nj}} \frac{\partial b_{nj}}{\partial w_{ji}} = \delta_j x_i (c)$$

Em que o vetor peso ( $w_t$ ) possuem valores dentro do conjunto dos Reais ( $R$ ) que multiplica o valor de entrada, em seguida subtrai-se com valor  $\theta$  de ativação caso o produto dessa subtração dê maior que o valor zero o perceptron permite a passagem do sinal, se o inverso ocorrer, cessa a emissão do sinal. Uma ANN utiliza da interação de várias unidades desses *perceptrons* em uma camada conforme a figura 01, a primeira camada de entrada é responsável por captar os dados exteriores da rede e direciona-los para cada um *perceptrons* na camada escondida L2 para depois realizar a soma desses valores na função 1.1 de ativação. Os sinais que resultam da camada L2 escondida na figura 01 convergem para a camada L3 de saída que realiza o processamento de todos esses sinais e resulta em uma única ativação final da rede com a decisão a ou classificação por uma função de ativação, neste caso de estudo função degrau, todo esse processo é descrito como *feedforward*. Depois de realizar o cálculo dos resultados obtidos da rede neural, é necessário validar esses resultados, mas o comumente utilizado é o erro absoluto presente na função  $b$ , com a obtenção do índice de acerto do sistema, é possível verificar eficácia do modelo servindo de parâmetro para a evolução da rede por meio do algoritmo *Backpropagation*, e o ajuste é feito quando mudam os pesos das interconexões entre os neurônios artificiais, esse ajuste é realizado da função  $c$  visando a um processo iterativo de ajustes de pesos rumo a minimização do erro do sistema por vetor gradiente descendente do erro ( $\partial E_n$ ),

buscando o valor mínimo global do erro absoluto do sistema por meio dessa função integrada no algoritmo de *Backpropagation* (MENDES,2020, p. 14).

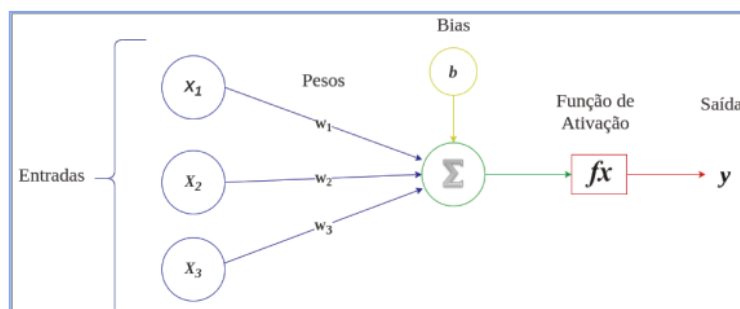
Para Moura (2021) as redes neurais foram inspiradas no funcionamento do cérebro humano, baseadas nas sinapses que são o sinal que transfere um neurônio para outro.

Quando há entradas suficientes, é quando inicia a comunicação entre os nós (neurônios), ativando a propagação das informações através da rede e obtendo como resposta o resultado.

Em termos práticos, em cada nó, os valores de entrada são multiplicados pelos pesos e desta forma, a rede consegue aprender. Uma vez somados estes nós serão aplicados a uma função de ativação e assim, este neurônio poderá ser ativado ou não.

Na figura 1 este processo é representado de forma clara, sendo que  $x_i$  representa as entradas e  $w_i$  são os pesos,  $b$  é o bias e por fim,  $f_x$  é a função de ativação e  $y$  é a saída.

**Figura 1: Representação de um neurônio**




**Fonte:** Moura (2021)

As redes neurais são usadas para aproximar uma função de valor ou política, possibilitando assim que ela consiga mapear os estados para valores ou pares de ação e estado para valores  $Q$ .

O objetivo do Aprendizado por Reforço é fazer treinamentos de uma rede neural através de amostras do estado ou espaço de ação, de tal forma que a rede neural aprenda a prever o quanto esses valores são importantes (DATA SCIENCE ACADEMY, 2022).

A figura 2 apresenta uma rede neural artificial de camada oculta, nesta rede as entradas são conectadas a muitos neurônios, que tem como efeito a saída de uma série de neurônios, onde cada neurônio se torna uma saída. Comparando com o sistema biológico, estas conexões simbolizam o contato dos dendritos com outros neurônios que formam as sinapses. A conexão tem a função de transformar o sinal de saída de um neurônio em um sinal de entrada de outro neurônio, ou em outra função, dirigir o sinal de saída para o exterior.

**Figura 2: Rede Neural Artificial de múltiplas camadas**

**Fonte:** Furtado (2019)

Estas diversas possibilidades de conexões entre as camadas de neurônio podem resultar em várias arquiteturas ou estruturas diferentes (FURTADO, 2019).

### 3 REDE ADVERSARIA GENERATIVA (GAN)

Redes Adversarias Generativas (GANs) são arquiteturas de redes neurais que contêm duas redes que são introduzidas uma contra a outra e por isso, é chamada de adversária e é uma das arquiteturas mais recente e fascinante do Deep Learning.

As GANs têm um enorme potencial, pois tem a capacidade de imitar qualquer distribuição de dados, elas podem criar mundos semelhantes aos nossos, seja na área da música, imagem, prosa, fala e podem ser consideradas como artistas robóticos devido a sua impressionante e comovente produção (DATA SCIENCE ACADEMY, 2023).

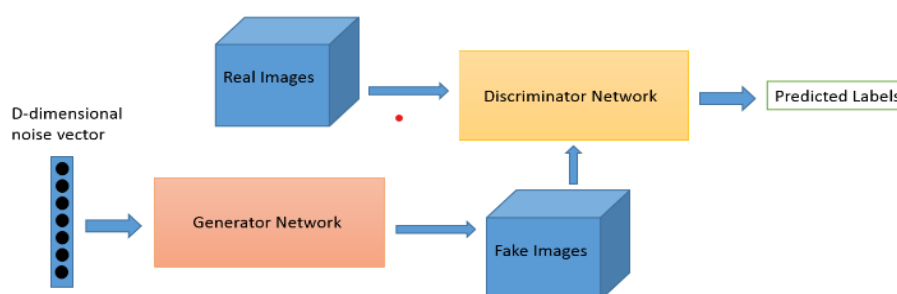
Recentemente, Goodfellow et al. (2014) propuseram as Redes Adversárias Generativas, as quais são implementadas por um sistema de duas redes neurais contestando-se em uma abordagem de soma zero<sup>8</sup>. A ideia por trás desta arquitetura é utilizar uma rede discriminativa em conjunto com uma rede generativa, onde a parte generativa é responsável por gerar dados artificiais a partir de ruídos e a rede discriminativa estimar a probabilidade das amostras (reais e artificiais) pertencerem aos dados reais. Conforme mencionado, uma Rede Adversarial Generativa é composta por duas arquiteturas: gerador e discriminador. Inicialmente, seja a função diferenciável da arquitetura do gerador definida por  $G$  e seus parâmetros definidos por  $\theta_G$ . Para aprender a distribuição probabilística do gerador sobre um conjunto de dados  $x \in X$ , é preciso definir um vetor de ruído (perturbação)  $z$  e representar um mapeamento do espaço de características para o espaço de dados, tal como  $G(z; \theta_G)$ . Adicionalmente, seja  $D$  a arquitetura representada pelo discriminador e seus parâmetros definidos por  $\theta_D$ , onde  $D(x; \theta_D)$  é a função que representa a saída desta rede e que fornece um valor escalar. Note que  $D(x)$  representa a probabilidade de um dado  $x$  pertencer ao espaço de dados  $X$  ao invés de pertencer ao espaço de dados artificiais (Rosa, 2022, p.47).

Santos (2020) escreve que as GANs formadas em uma formação de duas redes neurais que aprendem juntas através de uma competição mútua. A rede *D* é o discriminador que é responsável por identificar se um objeto está incluído em uma classe específica, ou seja, um classificador binário. Há também o gerador ou rede *G*, que é quem fornece uma entrada de valores aleatórios de maneira que forma um objeto que por sua vez, será analisado pela rede *D*.

Esta dinâmica entre redes faz com que a rede geradora busque gerar objetos que a rede discriminadora encontrará dificuldade de distinguir. Conforme a dificuldade vai sendo aumentada pela rede geradora, a rede discriminadora aprimora cada iteração de objetos de classificação, definindo se estes objetos pertencem a uma classe específica.

A figura 4 demonstra o funcionamento de uma GAN onde a rede neural gera nova instancia de dados e por isso é chamado de gerador. O discriminador faz a análise de autenticidade destes dados e decide se esta instancia pertence ou não ao conjunto de dados de treinamento real.

**Figura 3: Funcionamento da GAN**



**Fonte:** Data Science Academy, 2023.

### 3.1 Treinamento das GANs

A ideia que permeia as GANs em relação a treinamento, consiste em trocar a comparação direta pela indireta, que por sua vez, adquire a forma de uma tarefa ajustada sobre estas duas distribuições. Desta forma, o treinamento da GAN é realizado com relação a esta tarefa, forçando a distribuição gerada a se assemelhar cada vez mais a distribuição verdadeira.

A tarefa ajustada das GANs faz a discriminação entre a amostra verdadeira e a gerada, objetivando a falha ao máximo possível, pois em uma arquitetura GANs o discriminador faz o trabalho de classificar na melhor maneira possível os dados coletados e gerados, e neste caso, o gerador tem a função de enganar este discriminador (DATA SCIENCE ACADEMY, 2023).

Para estimar modelos geradores, foi criada uma arquitetura que treina duas redes simultaneamente, em processo adversário entre um modelo discriminador  $D$  e um gerador  $G$  chamado de redes geradoras adversárias (GAN). Nesta estrutura, o objetivo do gerador é criar amostras que sejam idealmente indistinguíveis de amostras reais, com o nível de semelhança entre elas sendo medido pelo discriminador. No caso específico em que os modelos são representados por redes neurais de *perceptrons* multicamadas (MLP), ambos podem ser treinados com o uso do algoritmo backpropagation [14]. Para tal, define-se uma distribuição conhecida  $p_z$  da qual são amostradas variáveis latentes de ruído  $z$ , representado por  $z \sim p_z$ . Usando uma rede neural  $G(z, \theta_g)$  parametrizada por  $\theta_g$  que tem como entrada o vetor  $z$ , é possível treiná-la para criar amostras de sua distribuição geradora implícita  $p_g$ . A rede discriminadora  $D(x, \theta_d)$  tem  $\theta_d$  como parâmetros e recebe como entrada imagens  $x_i$  amostradas de uma distribuição desconhecida  $p_{data}(x)$  ou geradas por  $G(z)$ , retornando a probabilidade de que a imagem em questão seja proveniente de  $p_{data}$ .  $D(x)$  dessa forma equivale a valores próximos a 1 quando a imagem vem de  $p_{data}$  e próximos a 0 quando a imagem é falsa, vinda de  $p_g$ , arquitetura vista na imagem 3.2. No caso ideal correspondente ao Equilíbrio de Nash do sistema, tem-se  $p_g = p_{data}$ . Vê-se assim que a rede discriminadora atua de forma supervisionada (com rótulos) para auxiliar a rede geradora, em um processo não-supervisionado. Um ponto interessante que surge como consequência desta configuração é que  $G(z)$  têm como ferramenta para aprimorar suas amostras apenas o feedback obtido por  $D(x)$ , sem nunca ter acesso direto às amostras reais (Mariz, 2018, p.13).

Neste processo de treinamento, cada iteração executada atualiza o peso da rede generativa e com isso, aumentam o erro de classificação, ou seja, sobe o gradiente de erro em cima dos parâmetros definidos pelo gerador e na contramão, o discriminador tem seus pesos diminuídos através da descida do gradiente de erro sobre os seus parâmetros.

A explicação para Redes Adversárias vem exatamente destes objetivos opostos, como também, da noção implícita do treinamento antagônico destas duas redes. Desta forma, estas duas redes tentam se derrotar e fazendo isso, elas melhoram cada vez mais e progredem com relação a seus objetivos (DATA SCIENCE ACADEMY, 2023).

### 3.2 Aplicações e usos de GANs

As GANs por ser um modelo generativo, tem a aplicação mais direta na geração de dados, pois ela aprende com dados reais e gera amostra consistente com a distribuição. Diversas aplicações podem ser realizadas pelas GANs, inclusive aplicações de domínio da visão computacional, linguagem natural, síntese de imagens de vídeos, tradução de imagens, super resolução de imagens, dentre outras aplicações (PAN et al, 2019).

Ledig et al (2017) propôs o uso de uma Rede Adversária Generativa de Super-Resolução ou SRGAN, que recebe uma imagem de baixa resolução e gerar uma imagem com 4 vezes mais resolução.



Rodrigues (2021) escreve que foi usado um tipo de GAN para a geração de imagens com várias camadas convolucionais que teve como resultado a geração de imagem em forma de matriz. Neste modelo foram geradas imagens de cômodos de uma residência, como também, imagens de rosto de pessoas.

#### **4 DEEPFAKES**

Com a sofisticação da tecnologia e o aprimoramento dos processos na geração de imagens e vídeos pela Inteligência Artificial, as *Deepfakes* têm evoluído e sendo usadas nas mais diversas situações. Elas se tornaram a principal ameaça à segurança cibernética e a privacidade das pessoas, pois são usadas para a disseminação de desinformação como também, a manipulação da opinião pública.

A produção de *Deepfakes* envolve a coleta de imagens e vídeos da face e corpo da pessoa no qual irá ser produzida ou imitada. Na sequência, para treinar o modelo de aprendizagem, estas imagens coletadas são usadas para mapear todos os movimentos corporais e faciais da pessoa no qual deseja imitar e após isso, aplica no vídeo original resultando na *Deepfake* (JOANGUETE, 2023).

Diversas formas de *Deepfakes* podem ser usadas, como:

- criar vídeos engraçados com um amigo ou familiar: isso pode parecer engraçado, mas pode ter um efeito negativo na reputação da pessoa, pois podem levar a situações embaraçosas e prejudicar sua reputação;
- Uso de falsa pornografia com pessoas reais: esta situação pode gerar danos emocionais e psicológicos na pessoa que foi envolvida nesta situação;
- Fraudes financeira: situação que pode envolver a transferência de dinheiro para uma conta fraudulenta, levando a perdas significativas de dinheiro por pessoas ou empresas (JOANGUETE, 2023).

O crescente uso de tecnologia para geração de *Deepfakes* para fins escuso, remetem a necessidade urgente de desenvolvimento de técnicas efetivas para sua detecção. Devido a esta demanda, vários setores têm buscado soluções para a detecção das *Deepfakes*, entre eles, a academia e o da indústria.

Uma parceria com a Meta e algumas universidades, como: MIT, *University of Oxford*, *UC Berkeley* e *University of Maryland* fizeram em 2020 a competição *Deepfake Detection*

*Challenge -DFDC*, onde foi apresentado um sistema que detectou as *Deepfakes* com 82 % de acurácia.

Várias técnicas de detecção de *Deepfakes* podem ser usadas, como: **Técnica de fusão:** onde os métodos de detecção de bordas podem ser usados para detectar os artefatos que surgem no processo de geração da imagem; **Técnica de ambiente:** onde anomalias são geradas pela inconsistência entre o conteúdo original e o gerado; **Análise forense:** onde métodos baseados na análise da diferença entre o padrão de frequência de uma câmera podem ser usados para detectar as marcas únicas deixadas pelas GANs (LEANDRO, 2022).

## 5 PROCEDIMENTOS METODOLÓGICOS

A metodologia usada para a composição deste artigo é a pesquisa bibliográfica, que deve ser construída através de materiais já elaborados, ou seja, em livros e artigos científicos, conforme escreve Gil (2002).

Na primeira etapa foi realizada uma pesquisa bibliográfica sobre os usos das redes neurais, suas funcionalidades e funções, bem como o uso da rede generativa adversária. Na sequência, foi elaborada a fundamentação teórica que forneceu elementos necessários para abordar o tema Redes Adversárias Generativas, como ela funciona, suas aplicações e implicações no desenvolvimento de ferramentas para o desenvolvimento e uso na geração de dados sintéticos semelhantes aos reais. Em seguida, foi apresentado os resultados e a discussão onde foram apresentadas as análises da pesquisa sobre o uso da Rede Adversária Generativa e suas aplicações nas mais diversas possibilidades. Por fim, foi sintetizada as conclusões finais baseada na pesquisa sobre a Rede Adversária Generativa e suas aplicações e abrindo espaço para eventuais estudos futuros.

## 6 RESULTADOS E DISCUSSÃO

No atual estado em que se encontra o uso da inteligência artificial e o crescente interesse na programação de redes que possa estabelecer as fronteiras entre diferentes classes e mapear as distribuições das mesmas, demonstram grande valor dos modelos geradores usados em redes não supervisionadas. Mesmo parecendo estranha e nebulosa, o estudo de modelos geradores se mostra essenciais para atuar nos espaços hiperdimensionais e de grande complexidade, conceito este da engenharia e matemática aplicada (MARIZ, 2018).

As GANs podem ser usadas nas mais diversas aplicações, como: na geração de face ou rosto, na detecção de objetos, na geração de vídeos, processamento de imagens na área médica e odontológica, gerando dados para área de Ciência de dados, aprendizagem e representação espacial, criação de perfis de utilizadores móveis, na segurança da informação como detecção de malware, esteganografia etc (GUI et al, 2015).

Com toda esta capacidade as GANs podem criar mundos muito parecidos com o nosso, seja ele o domínio que for, música, imagem, fala, prosa, elas são os artistas robóticos que tem uma produção comovente e impressionante (DATA SCIENCE ACADEMY, 2023).

## 5 CONCLUSÃO

As GANs são realmente revolucionárias em todo o seu contexto, com capacidade de aplicação nas mais diversas áreas. Seu conceito de modelagem antagônica permite a criação de dados artificiais muito semelhantes aos originais e que permite a criação de imagens, sons, personagens ou pessoas com tal fidelidade que a nós humanos é impossível de distinguir.

Toda esta capacidade, no entanto, traz preocupações com as *Deepfakes*, principal fator desagregador na aplicação das GANs, porém, novas ferramentas desenvolvidas pelas próprias GANs podem combater essas anomalias.

Apesar desta condição, as oportunidades de desenvolvimento e aplicação são enormes e traz grandes perspectivas para o futuro, onde o uso na medicina, na criação de arte, imagens fotográficas, vídeos, na própria segurança de dados, são alentos de esperança para o uso da humanidade.

## REFERENCIAS

DATA SCIENCE ACADEMY. Deep Learning Book. **Redes Neurais**, 2022. Disponível em: <https://www.deeplearningbook.com.br/?s=redes+neurais>. Acesso em: 17 Setembro 2023.

DE LA TORRE, JORDI. **Redes Generativas Adversarias (GAN) fundamentos teóricos y aplicaciones**. Pesquisa. Ph.D. in computer Science (ML/AI). Universitat Oberta de Catalunya, Barcelo, ES. 2023.

FACHIN, Odília. **Fundamentos de Metodologia**. 5.ed. São Paulo.Saraiva, 2006.

FURTADO, M. I. V. **Redes Neurais Artificiais: Uma abordagem para sala de aula**. Ponta Grossa, PR: Atena Editora, 2019.

GERHARDT, T. E; SILVEIRA, D. T. **Métodos de Pesquisa**. 1. ed. Rio Grande do Sul: Editora da UFRGS, 2009.

GIL, A.C. **Como elaborar projetos de pesquisa**. São Paulo: Atlas, 2002.

GOODFELLOW, I.; POUGET-ABADIE, J.; MIRZA, M.; XU, B.; WARDE-FARLEY, D.; OZAIR, S.; COURVILLE, A.; BENGIO, Y. Generative adversarial nets. In: **Advances in neural information processing systems**. S.l.: s.n., 2014. p. 2672–2680.

GUI, et al. A review on generative adversarial networks: Algorithms, theory and application. **Journal of latex class files**. Vol 14, no. 8, august 2015.

JOANGUETE, C. **O poder das mentiras digitais: a ameaça das Deepfakes para a sociedade**. Editora Dialética. 2023.

LEANDRO, J.J.G. **Deepfake: explorando técnicas de detecção de manipulação digital de imagens de faces**. Monografia. USP-Universidade de São Paulo, São Carlos.2022.

LEÃO, E. T.; FIGUEIREDO, R. C. **Um estudo comparativo sobre redes adversárias generativas**. Trabalho de conclusão de curso. Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2022.

LEDIG et al. **Photo-realistic single image super-resolution using a generative adversarial network**. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR), Jul. 2017, pp. 105–114.

MARIZ, L. F. **Redes Geradoras Adversárias em geração de imagens**. Trabalho de Conclusão de curso. Universidade de Brasília, Brasília, 2023.

MENDES, P. H. R. **Geração de música polifônica utilizando redes neurais artificiais**. Pesquisa científica de pós-graduação. UNICEUB, Centro Universitário de Brasília. Brasília, 2020.

MOURA, C.S.F.T. **Deteção de Deepfakes a partir de técnicas de visão computacional e aprendizado de máquina**. Dissertação de mestrado. Universidade Estadual de Campinas, Campinas, 2021.

PAN, Zhaoqing; YU, Weijie; YI, Xiaokai; KHAN, Asifullah; YUAN, Feng; ZHENG, Yuhui. Recent Progress on Generative Adversarial Networks (GANs): A Survey. **IEEE Access - Open Access Journal**, march 2019.

RODRIGUES, M. F. **Geração de dados sintéticos utilizando redes neurais artificiais**. Trabalho de conclusão de curso. Universidade Federal do Ceará, 2021.

REIS, R. L. C. **Seleção de portfólios usando redes neurais adversárias generativas para a modelagem do processo estocástico de retornos**. Dissertação de mestrado. UFRJ-Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2019.

ROSA, G. H. **Análise de aprendizado adversarial baseado em similaridade na geração de texto**. Tese. Unesp. Bauru, 2022.

SANTOS, J. S. **Geração e aplicação de imagens sintéticas da região dos olhos para o aumento de performance de técnicas da detecção do estrabismo.** Dissertação de Mestrado. Universidade Presbiteriana Mackenzie. São Paulo, 2020.