

Adaptação de Domínio na Geração de Dados Sintéticos de Imagens

Uma Abordagem com DCGAN Integrada a CNN
de Feedback

Luan Gabriel Silva Oliveira



UNIVERSIDADE FEDERAL DE GOIÁS (UFG)
INSTITUTO DE INFORMÁTICA (INF)

LUAN GABRIEL SILVA OLIVEIRA

Adaptação de Domínio na Geração de Dados Sintéticos de Imagens

Uma Abordagem com DCGAN Integrada a CNN de Feedback

Goiânia
2025



UNIVERSIDADE FEDERAL DE GOIÁS
INSTITUTO DE INFORMÁTICA

TERMO DE CIÊNCIA E DE AUTORIZAÇÃO PARA DISPONIBILIZAR VERSÕES ELETRÔNICAS DE TRABALHO DE CONCLUSÃO DE CURSO DE GRADUAÇÃO NO REPOSITÓRIO INSTITUCIONAL DA UFG

Na qualidade de titular dos direitos de autor, autorizo a Universidade Federal de Goiás (UFG) a disponibilizar, gratuitamente, por meio do Repositório Institucional (RI/UFG), regulamentado pela Resolução CEPEC no 1240/2014, sem ressarcimento dos direitos autorais, de acordo com a Lei no 9.610/98, o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou download, a título de divulgação da produção científica brasileira, a partir desta data.

O conteúdo dos Trabalhos de Conclusão dos Cursos de Graduação disponibilizado no RI/UFG é de responsabilidade exclusiva dos autores. Ao encaminhar(em) o produto final, o(s) autor(a)(es)(as) e o(a) orientador(a) firmam o compromisso de que o trabalho não contém nenhuma violação de quaisquer direitos autorais ou outro direito de terceiros.

1. Identificação do Trabalho de Conclusão de Curso de Graduação (TCCG)

Nome(s) completo(s) do(a)(s) autor(a)(es)(as): LUAN GABRIEL SILVA OLIVEIRA

Título do trabalho: Adaptação de Domínio na Geração de Dados Sintéticos de Imagens

Uma Abordagem com DCGAN Integrada a CNN de Feedback

2. Informações de acesso ao documento (este campo deve ser preenchido pelo orientador) Concorda com a liberação total do documento SIM NÃO¹

[1] Neste caso o documento será embargado por até um ano a partir da data de defesa. Após esse período, a possível disponibilização ocorrerá apenas mediante: a) consulta ao(a)(s) autor(a)(es)(as) e ao(a) orientador(a); b) novo Termo de Ciência e de Autorização (TECA) assinado e inserido no arquivo do TCCG. O documento não será disponibilizado durante o período de embargo.

Casos de embargo:

- Solicitação de registro de patente;
- Submissão de artigo em revista científica;
- Publicação como capítulo de livro.

Obs.: Este termo deve ser assinado no SEI pelo orientador e pelo autor.



Documento assinado eletronicamente por **Luan Gabriel Silva Oliveira, Discente**, em 12/01/2025, às 21:54, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Fernando Marques Federson, Professor do Magistério Superior**, em 15/01/2025, às 16:21, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **5089791** e o código CRC **71F40633**.

Referência: Processo nº 23070.001592/2025-15

SEI nº 5089791

LUAN GABRIEL SILVA OLIVEIRA

Adaptação de Domínio na Geração de Dados Sintéticos de Imagens
Uma Abordagem com DCGAN Integrada a CNN de Feedback

Relatório final de Trabalho de Conclusão de Curso, apresentado à Universidade Federal de Goiás, como parte das exigências para a obtenção do título de Bacharel em Inteligência Artificial.
Orientador: Prof. Dr. Fernando Marques Federson

Goiânia
2025

Ficha de identificação da obra elaborada pelo autor, através do Programa de Geração Automática do Sistema de Bibliotecas da UFG.

OLIVEIRA, LUAN GABRIEL SILVA

Adaptação de Domínio na Geração de Dados Sintéticos de Imagens [manuscrito] : Uma Abordagem com DCGAN Integrada a CNN de Feedback / LUAN GABRIEL SILVA OLIVEIRA. - 2025.
97 f.

Orientador: Prof. Dr. Fernando Marques Federson.
Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de Goiás, Instituto de Informática (INF), Inteligência Artificial, Goiânia, 2025.

1. inteligência artificial. 2. geração de dados sintéticos. 3. adaptação de domínio. I. Federson, Fernando Marques , orient. II. Título.

CDU 004

LUAN GABRIEL SILVA OLIVEIRA

Adaptação de Domínio na Geração de Dados Sintéticos de Imagens
Uma Abordagem com DCGAN Integrada a CNN de Feedback

Relatório final de Trabalho de Conclusão de Curso, apresentado à Universidade Federal de Goiás, como parte das exigências para a obtenção do título de Bacharel em Inteligência Artificial.

Data da Aprovação: 17 de dezembro de 2024.



Prof. Dr. Fernando Marques Federson
Orientador (INF-UFG)



Prof. Dr. Aldo André Díaz Salazar
Coordenador de TCC do BIA (INF-UFG)



Prof. Dr. Anderson da Silva Soares
Coordenador do BIA (INF-UFG)



Prof. Dr. Iwens Gervasio Sene Junior
(INF-UFG)

LUAN GABRIEL SILVA OLIVEIRA

Adaptação de Domínio na Geração de Dados Sintéticos de Imagens

Uma Abordagem com DCGAN Integrada a CNN de Feedback

RESUMO

Este Relatório de Conclusão de Curso tem como objetivo reunir os resultados da minha jornada para me tornar um especialista em **Geração de Dados Sintéticos com Adaptação de Domínio**. Uma ilustração e sua narrativa descrevem os períodos de trabalho. Os Apêndices contêm os Termos de Aceite de Entrega e os resultados obtidos durante cada período de trabalho.

Palavras-chave: inteligência artificial, modelos grandes de linguagem, geração automática de datasets.

ABSTRACT

This Course Completion Report aims to bring together the results of my journey to become an expert in **Synthetic Data Generation with Domain Adaptation**. An illustration and its narrative describe the work periods. The Appendices contain the Delivery Acceptance Terms and the results obtained during each work period.

Keywords: artificial intelligence, large language models, automatic dataset generation.

Goiânia

2025

Minha Jornada

Luan Gabriel Silva Olivera
Especialista em: Geração de Dados Sintéticos
com Adaptação de Domínio



MINHA JORNADA

Nome: Luan Gabriel Silva Oliveira

Especialidade: Geração de Dados Sintéticos com Adaptação de Domínio

Objetivo deste documento

Durante o processo da disciplina Residência em IA¹, foram gerados diversos resultados na construção da minha especialização. A cada semana, um conjunto de resultados foi formalizado por um Termo de Aceite de Entrega e avaliado por uma banca, considerando o planejado e o realizado para o período. Este documento tem como objetivo descrever esses resultados obtidos, fazendo referência aos Termos de Aceite de Entrega e seus documentos associados.

Minha Jornada

Minha Jornada começou na **Semana 1** com atividades para definir a área de conhecimento da minha especialização. A partir da chamada dos Congressos, em especial do Congresso IPCV'24 - The 28th Int'l Conf on Image Processing, Computer Vision, & Pattern RecognitionX, pude perceber a abrangência dos grandes temas relacionados à geração e segmentação de imagens os quais me chamaram a atenção como área de interesse. Ademais, a formação obtida nas disciplinas: Processamento Digital de Sinais e Imagens e Aprendizado Não Supervisionado do Bacharelado também foram importantes para a minha escolha de tema. Com a leitura de alguns artigos e e-books, bem como o estudo de vídeo-aulas relacionadas ao assunto, pude decidir, na **Semana 2**, que gostaria de me aprofundar na área de **Geração de Dados Sintéticos de Imagens**. Realizei uma busca por artigos utilizando a ferramenta ResearchRabbit. Com ela, pude organizar os artigos selecionados com base em similaridade por título e/ou por autor, o que otimizou tanto a busca quanto a escolha dos artigos mais relevantes para minha escolha de tema. As referências lidas, assim como algumas observações que considero importantes, podem ser

¹ Dez semanas, entre setembro de 2024 e dezembro de 2024.

obtidas em detalhes no material disponibilizado no **Apêndice 1**. Um artigo que gostaria de destacar aqui foi o de Tasleem Kausar et al². O autor demonstra que a área voltada para a geração de imagens sintéticas, em especial utilizando modelos como Redes Generativas Adversárias (GANs) podem mitigar questões como a escassez de dados relevantes em um dataset, principalmente em casos onde esses dados são de difícil coleta e/ou sensíveis por exemplo dados relativos à área da saúde, bem como eventos raros que precisam ser levados em consideração. Outros autores, relacionados no **Apêndice 1**, argumentam que a área de Geração de Dados Sintéticos de Imagens pode ser aplicada em diversos contextos visto que utilizar dados gerados sinteticamente com a finalidade de aumentar uma base de dados, podem melhorar o desempenho e as capacidades de modelos de aprendizado profundo como modelos de detecção e segmentação de imagens, os quais dependem de uma grande quantidade de dados para um bom funcionamento.

A partir da definição da área, e das primeiras revisões bibliográficas realizadas, foi possível, na **Semana 3**, identificar quais os modelos de geração de imagem eram mais difusos, o que permitiu o início de um estudo bibliográfico simples e o início da leitura de artigos relacionados aos modelos de geração de imagens sintéticas. No **Apêndice 2**, é possível encontrar a relação completa dos artigos lidos com algumas observações. Este material serviu de base para a continuidade dos trabalhos realizados, em especial, na organização do conhecimento e direcionamento da jornada. Por exemplo, ficou claro que modelos Generativos, como as GANs são excepcionais no contexto de gerar imagens com qualidade utilizando poucos recursos computacionais. Para mais, este modelo pode ser implementado em diferentes cenários, como em Robótica, Saúde, Ambientes Simulados entre outros. Portanto, concluí que utilizar um modelo Generativo para gerar imagens sintéticas poderia ser relevante em diferentes campos de aplicação.

As **Semanas 4 e 5** foram utilizadas para estudar o processo e entender os passos necessários para implementação de uma Rede Generativa Adversária, inferindo quais as ferramentas mais utilizadas e quais os tipos de dados sintéticos podem ser gerados. Durante

² Kausar, T. SD-GAN: A Style Distribution Transfer Generative Adversarial Network for Covid-19 Detection Through X-Ray Images, 2023.

essa etapa foi identificado um problema muito recorrente no que diz respeito aos dados gerados sinteticamente. A Adaptação de Domínio, segundo Tzeng (2017), modelos de reconhecimento treinados com em um grande conjunto de dados não generalizam bem para novos conjuntos de dados e tarefas, ou seja, os modelos treinados com dados sintéticos podem não aprender algumas características presentes nos dados reais pois essas características não estão sendo representadas. A solução convencional seria reajustar o modelo em conjuntos de dados mais específicos, o que pode ser custoso, tanto no âmbito computacional quanto na disponibilidade de dados. A solução sugerida pelo autor seria a geração de dados sintéticos com Adaptação de Domínio, ou seja, modelos generativos capazes de criar novos dados mais parecidos com os dados reais, levando em consideração as características relevantes dos dados originais. **No Apêndice 3**, foi fornecido um material explicativo, tanto do processo de implementação quanto do problema da Adaptação de Domínio de maneira mais detalhada.

Dado o problema da Adaptação de Domínio descrito, iniciei os estudos de maneiras possíveis para atenuá-lo e pensei na possibilidade de integrar uma GAN com uma Rede Neural Convolucional com a seguinte finalidade: Enquanto a GAN é responsável por gerar as imagens sintéticas, a CNN (Convolutional Neural Network) será responsável por avaliá-las comparando-as com as imagens reais. Com base nas características gerais extraídas pela CNN, um feedback da qualidade das imagens é repassado para a GAN com o intuito de repassar para a Rede Generativa as características mais relevantes com base nas informações dos dados reais para que as próximas imagens geradas sejam mais parecidas com os dados originais. A partir dos estudos realizados sobre a possibilidade de integrar essas duas Redes, decidi que para a **Semana 6** iniciaria o processo de implementação das Redes Generativas com a finalidade de colocar em prática o que havia sido estudado, bem como visualizar na prática como ocorre a Adaptação de Domínio. Portanto, foi implementada uma GAN simples em um dataset de imagens de mapas a partir de imagens de satélites. O processo de implementação da GAN tal qual o código implementado estão disponíveis no **Apêndice 4**. Foi observado que as imagens geradas sinteticamente a partir desse modelo de GAN simples, eram ligeiramente diferentes das imagens reais, uma vez que, algumas áreas dos mapas gerados não eram bem representados.

Após a implementação de uma GAN simples e observado, algumas inconsistências entre os dados sintéticos e os dados reais, propus que, para a **Semana 7**, seria realizada uma integração de uma CNN a um modelo de GAN para atenuar o problema da falta de Adaptação de Domínio do modelo. Com isso, foi selecionado um artigo em que o uso de redes adversariais generativas em aprendizado não supervisionado foi proposto pelos autores (RADFORD; METZ, 2016). Nesse contexto, o paper faz a implementação de um Rede Generativa Adversária de Convolução Profunda (DCGAN) utilizando o dataset do CelebA. Meu Objetivo para desenvolvimento foi implementar a mesma DCGAN do artigo, porém com uma CNN de Feedback para avaliar se a integração destas duas Redes seria capaz de mitigar a questão da Adaptação de Domínio. O estudo comparativo entre os dois modelos - DCGAN do artigo e DCGAN com CNN de Feedback - apresentaram resultados sólidos e próximos. Portanto fez-se necessário utilizar métricas de avaliações mais avançadas para que pudesse ser feito um estudo comparativo mais robusto entre ambos os modelos. A integração da DCGAN com CNN de Feedback, assim como as primeiras análises se encontram no **Apêndice 4**.

As **Semanas 8 e 9** foi destinada à avaliação dos modelos de DCGAN do artigo com o modelo de DCGAN com CNN de Feedback. Para isso, foi utilizado o mesmo dataset do artigo, o CelebA com dados de imagens da face de celebridades e pessoas influentes com diversos atributos, como óculos, chapéus, tipos de cabelo e muitos outros. Para realizar uma avaliação justa entre os modelos, foi selecionado uma amostra de 1.000 imagens com 10 atributos selecionados: Cabelos pretos; Franja; Careca; Atraente; Lábios Grandes; Nariz Grande; Sobrancelhas Arqueadas; Masculino; Sorridente e Sombra embaixo dos olhos. Ambos os modelos foram treinados pelo mesmo número de épocas (25) com os mesmos hiperparâmetros e recursos computacionais. As métricas de avaliação utilizadas foram: Inceptions Score, Fréchet inception distance, Diversity Score. A cada época de treinamento, as métricas foram calculadas para que fosse possível observar como ambos os modelos estavam aprendendo e evoluindo. Essas métricas foram selecionadas com o intuito de avaliar a qualidade da imagem gerada e o quão próxima ela está da imagem real. Todavia, enquanto na **Semana 8** esperava obter resultados melhores em se tratando da comparação dos modelos, na **Semana 9** os resultados não foram satisfatórios, uma vez que, de acordo

com as métricas avaliadas o modelo de DCGAN do artigo foi superior tanto na qualidade da imagem gerada quanto na proximidade com as imagens reais as análises comparativas e documentadas estão dispostas no **Apêndice 5**. Levantei algumas hipóteses do porque o modelo de DCGAN com CNN de Feedback performou razoavelmente pior, sendo a principal, o conjunto de dados utilizado. O Dataset com as 1.000 amostras de imagens era muito pequeno para que a CNN conseguisse extrair um maior número de características das imagens reais e conseqüentemente gerar imagens com maior qualidade.

Nesse âmbito, decidi que para a **Semana 10** faria duas atualizações. Primeiro utilizaria 200.000 imagens do Dataset do CelebA, para assim conseguir mais amostras diversas no treinamento dos modelos. Além disso, realizei a implementação de Mecanismos de Atenção, mais especificamente o SelfAttention nas camadas da Rede Neural Convolutiva para extrair características mais específicas e menos recorrentes das imagens, acreditei que, com esse plus em minha arquitetura, seria capaz de extrair ainda mais informações das imagens reais para enfim retorná-las ao Gerador da DCGAN para que, com base nessas características, ele pudesse gerar imagens mais fiéis às imagens reais. Após as devidas atualizações, foram utilizadas as mesmas métricas de avaliação da **Semana 9** com o intuito de observar a evolução do desempenho dos modelos. Com o aumento das amostras do Dataset do CelebA, e a implementação de Mecanismos de Atenção, a DCGAN com CNN de Feedback conseguiu superar a DCGAN do artigo em relação a qualidade das imagens geradas e da capacidade de gerar imagens diversas a partir do conjunto de dados original. Outrossim, observou-se que ao utilizar uma CNN como Feedback para a DCGAN, o tempo de execução foi ligeiramente menor, ou seja, o modelo de DCGAN com CNN de Feedback foi capaz de gerar imagens de maior qualidade e mais parecidas com as imagens reais em um tempo de treinamento menor. A implementação dos Mecanismos de Atenção, bem como a reavaliação dos modelos pode ser encontrada no **Apêndice 6**.

Em função de tudo que vivi nesta Jornada, gostaria de deixar registrado que foi uma experiência enriquecedora e de muita responsabilidade. Foram alguns meses de dedicação e trabalho para conseguir desenvolver algo que fizesse, não apenas sentido para os responsáveis pela Banca, mas para mim também, enquanto estudante e pesquisador.

Encerro esse processo mais maduro e com conhecimentos relevantes para minha futura carreira acadêmica e profissional. Tive contato com muitas ferramentas que podem ser aplicadas em diversas áreas do conhecimento, como ferramentas mais utilizadas no processo de Geração de imagens, fui capaz de identificar um problema muito recorrente no que diz respeito à utilização de Dados Sintéticos de imagens e me propus a tentar mitigá-lo. Com isso enfrentei muitos entraves e desafios que fortaleceram-me no âmbito da pesquisa capacitando-me a buscar soluções alternativas em diferentes cenários utilizando ferramentas e técnicas variadas. O resultado satisfatório do meu modelo de DCGAN com CNN de Feedback em relação a DCGAN do artigo, é reflexo do meu empenho e seriedade em viver o processo de Residência em Inteligência Artificial.

Fui capaz de entender que este momento me permitiria experimentar novas possibilidades e buscar soluções não convencionais. Por conta disso, norteiei meu trabalho seguindo por um caminho incerto, porém intrigante. O processo foi vivido e aproveitado de maneira sólida. Cada etapa vencida, desde a seleção do tema de Geração de Dados Sintéticos de Imagem, a busca por artigos relacionados ao tema, posteriormente a procura por artigos que implementaram modelos de generativos, a detecção de um problema recorrente no domínio dos dados gerados sinteticamente até a investigação para encontrar soluções e a implementação de uma solução jamais vista e/ou implementada fazem-me sentir a sensação de dever cumprido. Colocar em prática muito do que foi apresentado e desenvolvido durante as disciplinas, na Residência em Inteligência Artificial, é uma maneira de enxergar como, por mais que longo, o processo foi proveitoso e, olhando para trás, consigo enxergar o quanto evoluí como pessoa, estudante e pesquisador, e o quanto ainda preciso e posso evoluir para me tornar um ser humano melhor. Afirmando com todas as letras que a Inteligência Artificial fez de mim um ser mais humano.

APÊNDICE 1

Termo de Aceite de Entrega

Objetivo deste documento

Este documento faz parte do Processo da disciplina Residência em IA e tem como objetivo formalizar o aceite da entrega considerando o planejado e o realizado para o período.

Data da Reunião (“gate”) de aprovação: 19 de set. de 2024

Participantes da Entrega [matriculados em Residência em IA]:

Luan Gabriel Silva Oliveira

Entrega: [descrever a ENTREGA: requisitos e produtos gerados: links para textos, códigos, vídeos etc.]

Revisão histórica sobre Dados Sintéticos: Ebook: [Accelerating AI with Synthetic Data](#)

- Definição de dados sintéticos
 - Dados que foram gerados a partir de dados reais e que possuem as mesmas propriedades estatísticas dos dados reais.
- Estudos de casos
 - Health Care: Dificuldade em conseguir dados reais, bem como regulações de privacidade para dados sensíveis;
 - Transportation: Microsimulation Models permitem análises hipotéticas e novos cenários. Avaliar o impacto da nova infraestrutura planejada
- Formas de criar dados sintéticos
 - A partir de dados quais tipos de dados (Estruturados/Não Estruturados)

[Aqui](#) está o resumo do estudo sobre o Ebook citado.

Aplicações para Dados Sintéticos?

Assisti a algumas vídeo-aulas de implementação de dados sintéticos. Das quais a que mais me chamou atenção foi a implementação de uma GAN para gerar dados sintéticos a partir do Dataset Fashion MNIST

- Vídeo aula sobre: [Abordagens relevantes para o uso/aplicação dos Dados Sintéticos](#)
 - Implementação de GAN (Rede Adversária Generativa) para Sintetização de imagens no Fashion MNIST
 - <https://github.com/nicknochnack/GANBasics/blob/main/FashionGAN-Tutorial.ipynb>

Planejamento: [descrever o que pretende fazer para realizar a próxima ENTREGA]

Como houve um entendimento acerca da história dos dados sintéticos, o processo de sintetização de dados sintéticos bem como os casos de aplicação. Pretendo, como seguimento de meu trabalho e estudo:

- Continuar os estudos provenientes do Ebook
 - Processo de implementação dos dados Sintéticos
- Buscar artigos relacionados a Dados sintéticos, que envolvam detalhes de implementação
 - Práticas recomendadas para implementar a síntese de dados
- Estudo de frameworks aplicáveis a diferentes tipos de Dados sintéticos que podem ser gerados (Texto, Imagem)
- Estudar como extrair informações relevantes sobre os Dados Sintéticos.

Observação: [caso precise fazer alguma observação, de qualquer “natureza”]

ACEITE DA ENTREGA:

CEDRIC LUIZ DE CARVALHO: Go! ▾

Synthetic Data

1. O que são Dados Sintéticos?

Dados sintéticos não são dados reais, mas sim gerados a partir de dados reais, mantendo as mesmas propriedades estatísticas e garantindo que análises feitas com eles tenham resultados semelhantes aos que seriam obtidos com dados reais. A qualidade desse tipo de dado é medida pela sua proximidade com os dados reais e pela sua utilidade para análises específicas

Tipos de dados sintéticos:

1. **Gerados a partir de dados reais:** Um modelo é criado para capturar a estrutura e as distribuições dos dados reais, e a partir desse modelo, dados sintéticos são gerados.
2. **Gerados sem dados reais:** Criados usando modelos existentes ou conhecimento prévio, como simulações ou suposições baseadas em eventos conhecidos.

2. Benefícios dos dados sintéticos

Facilita o acesso a grandes volumes de dados sem implicações legais ou de privacidade, especialmente em projetos de IA/ML. Ademais, os dados sintéticos oferecem mais diversidade e heterogeneidade, que muitas vezes não estão disponíveis em conjuntos de dados públicos, além de possibilitar a rotulagem automatizada. Dados sintéticos podem ser usados para treinamento inicial de modelos, acelerando o processo de aprendizado quando os dados reais estiverem disponíveis. Por fim, eles podem cobrir cenários de dados inexistentes ou impraticáveis de serem coletados, como em situações raras ou extremas.

3. Gerando Dados Sintéticos a partir de Dados Reais

O processo para geração de dados sintéticos a partir de dados reais, envolve a construção de um modelo a partir de dados reais e a geração de novos dados com base nesse modelo. O processo segue um ciclo de geração e discriminação até que os dados sintéticos sejam suficientemente similares aos reais.

Técnicas de Geração:

- **Métodos Simples:** Envolvem ajuste de distribuições e correlações entre as variáveis.

- **Técnicas Avançadas:** Podem incluir interações complexas entre as variáveis usando métodos como árvores de decisão ou aprendizado profundo (deep learning).
- **Prevenção de Overfitting:** Evitar a replicação exata dos dados reais é essencial para garantir privacidade e originalidade.
- **Métodos Adversariais:** Algumas abordagens, como Redes Adversariais Generativas (GANs), usam entradas aleatórias para gerar dados sintéticos por meio de aprendizado iterativo.

Estudo de casos:

1. Health Care

O acesso a dados de saúde é frequentemente difícil devido a regulamentações de privacidade, como a **LGPD**, além dos altos custos de coleta de dados em estudos clínicos. Nesse sentido, empresas e tecnologia médica podem usar dados sintéticos para avaliar novas inovações, como algoritmos de aprendizado de máquina e ferramentas de análise, antes de comprometer recursos com a aquisição de dados reais.

A digitalização da saúde, como a introdução de dispositivos médicos que geram dados contínuos e o uso de dados genômicos, é facilitada pela criação de dados sintéticos, permitindo avanços na personalização de tratamentos médicos.

Uso de Dados Sintéticos para Pesquisa:

- **Privacidade:** Dados sintéticos ajudam a preservar a privacidade dos pacientes ao substituir dados reais em estudos e análises.
- **Exemplo Prático apresentado no Ebook:** O uso de dados sintéticos em registros de câncer no Reino Unido permite que pesquisadores realizem estudos e testes de viabilidade de maneira mais rápida e econômica.

2. Transportation

Dados sintéticos são amplamente utilizados para treinar e testar modelos de IA em **veículos autônomos**, uma vez que simular todos os cenários possíveis no mundo real seria impraticável ou até perigoso. Com isso, faz-se necessário a utilização de simuladores que criam cenários que imitam o mundo real com alta fidelidade, permitindo que modelos de IA sejam testados em situações complexas e raras, como acidentes ou condições extremas.

- **Exemplo Prático apresentado no Ebook:** Empresas como a NVIDIA utilizam simuladores para gerar dados sintéticos em testes de veículos autônomos, o que

possibilita a validação e aprimoramento de software e hardware sem riscos no mundo real.

O uso de dados sintéticos em transportes, especialmente para autônomos, reduz custos e riscos, uma vez que testes extensivos podem ser conduzidos virtualmente antes de serem aplicados em cenários reais.

Dados Sintéticos Estruturados:

São dados organizados em um formato bem definido, como tabelas, com linhas e colunas, tipicamente armazenados em bancos de dados relacionais. Exemplos incluem registros financeiros, informações de clientes, e dados demográficos.

Para gerar esses dados, um modelo é construído para capturar as distribuições estatísticas e relações entre as variáveis (por exemplo, entre idade e renda). A partir desse modelo, novos dados são criados que mantêm a mesma estrutura e correlações observadas nos dados originais.

2. Dados Sintéticos Não Estruturados:

Dados que não seguem um formato organizado e regular. Exemplos incluem textos (como notas de médicos), conversas em áudio, imagens, vídeos e interações online, como e-mails ou chats.

Sua criação é mais complexa e pode envolver técnicas como simulações ou algoritmos que imitam o comportamento dos dados originais. Por exemplo, para gerar imagens sintéticas, podem ser usados algoritmos como GANs (Redes Adversariais Generativas) que criam fotos de rostos humanos que parecem reais, mas não correspondem a nenhuma pessoa existente.

Principais diferenças:

- **Estruturados:** Seguem uma organização clara (tabelas e colunas), sendo mais fáceis de gerenciar e analisar diretamente.

Não Estruturados: Exigem técnicas mais avançadas de processamento para serem sintetizados e analisados devido à sua natureza mais caótica e variada, como o processamento de linguagem natural (NLP) ou visão computacional para imagens.

Termo de Aceite de Entrega

Objetivo deste documento

Este documento faz parte do Processo da disciplina Residência em IA e tem como objetivo formalizar o aceite da entrega considerando o planejado e o realizado para o período.

Data da Reunião (“gate”) de aprovação: 25 de set. de 2024

Participantes da Entrega [matriculados em Residência em IA]:

Luan Gabriel Silva Oliveira

Entrega: [descrever a ENTREGA: requisitos e produtos gerados: links para textos, códigos, vídeos etc.]

Busca por artigos relacionados a Dados Sintéticos e métodos de implementação

- Screening buscando identificar os objetivos e problemas que cada estudo visa resolver.
 - [SD-GAN: Uma rede adversária generativa de transferência de distribuição de estilo](#)
 - [medigan: Uma biblioteca completa com vários GANs pré-treinados para a geração de dados sintéticos de imagens médicas \(mamografias, ressonância magnética cerebral, endoscopia, radiografia de tórax\)](#)
- Refinei a análise de artigos específicos “Re-screening” para identificar detalhes sobre as implementações, modelos/algoritmos utilizados e métricas de avaliação aplicadas.
 - Levantamento de estudo: Buscar na introdução dos artigos uma visão geral do projeto, linkando com a abordagem da solução;
 - Códigos Open-source ou bibliotecas usadas;
 - Área de aplicação: Saúde foi o setor mais presente, com estudos focados em gerar dados sintéticos para diagnósticos e simulações de doenças;
 - Link para os artigos utilizados e seus respectivos repositórios
[Artigos-SyntheticData](#)
- Estudo aprofundado realizado no “Re-screening” anotações
 - Paralelismo entre o escopo do trabalho, a solução desejada e as ferramentas utilizadas
 - Organizei as informações em uma tabela destacando o escopo, abordagens estatísticas, frameworks utilizados e métricas de avaliação dos artigos selecionados.
 - Link para o estudo aprofundado:
[Estudo-aprofundado](#)

Planejamento: [descrever o que pretende fazer para realizar a próxima ENTREGA]

Com base no estudo dos artigos utilizando o método Screening, observei padrões que se assemelham, tanto na área de aplicação quanto nas ferramentas utilizadas para geração dos dados sintéticos. Porém não é a única área de aplicação tampouco a única/melhor ferramenta para determinados cenários. Com isso, pretendo, como seguimento de meu trabalho e estudo:

- Exploração de novos artigos em outras áreas de aplicação
 - Financeira, marketing, jogos
- Buscar artigos com metodologias menos exploradas
 - Deep Learning?
 - Federated Learning?
- Buscar ferramentas que automatiza o processo de screening
 - Extrair informações-chave do objetivo do projeto, metodologia aplicada e ferramentas utilizadas

Observação: [caso precise fazer alguma observação, de qualquer “natureza”]

ACEITE DA ENTREGA:

LEONARDO ALVES: Go! ▾

Principais Artigos Estudados

Artigo 36: “**A computational pipeline for data augmentation towards the improvement of disease classification and risk stratification models: A case study in two clinical domains**”

- **Visão Geral da Introdução:**

A introdução descreve o papel crucial da geração de dados virtuais no desenvolvimento de modelos de machine learning robustos para classificação de doenças e estratificação de riscos em domínios clínicos. As abordagens estatísticas mencionadas, como modelos Bayesianos, árvores de decisão e redes neurais artificiais com funções de base radial (RBF), são fundamentais para gerar dados de alta qualidade que mimetizam os dados clínicos reais. As métricas de Goodness of Fit (GOF), Divergência de Kullback-Leibler (KLD) e Correlação Cruzada (CC) são utilizadas para garantir a precisão e a qualidade dos dados virtuais, avaliando sua similaridade com os dados reais e a manutenção da privacidade das informações originais.

- **Abordagens Estatísticas/Algoritmos Usados:**

Este artigo emprega métodos de geração de dados virtuais que incluem modelos Bayesianos, conjuntos de árvores (tree ensembles) e redes neurais artificiais com funções de base radial (RBF-based ANNs). Esses métodos são aplicados para gerar dados clínicos virtuais de alta qualidade.

- **Métricas de Medição:**

As métricas usadas para avaliar a fidelidade e a privacidade dos dados incluem Goodness of Fit (GOF), Divergência de Kullback-Leibler (KLD) e Correlação Cruzada (CC). Estas métricas ajudam a avaliar quão bem os dados virtuais replicam as distribuições dos dados reais e a manter a privacidade das informações originais.

Artigo 19: “**Bayesian Inference-Based Gaussian Mixture Models With Optimal Components Estimation Towards Large-Scale Synthetic Data Generation for In Silico Clinical Trials**”

- **Visão Geral da Introdução:**

Esta introdução aborda a necessidade de superar a falta de tamanhos populacionais suficientes em ensaios clínicos através da geração de dados sintéticos. O uso de modelos de mistura gaussiana otimizados por inferência bayesiana (BGMM-OCE) destaca-se como

uma abordagem eficiente para criar distribuições sintéticas que se alinham bem com os dados reais. Métricas como Variação Coeficiente (cV), GOF, KLD e CC são empregadas para medir a precisão e a confiabilidade dos dados sintéticos, garantindo que eles sejam uma réplica fiel dos dados originais e preservem a privacidade.

- **Abordagens Estatísticas/Algoritmos Usados:**

O artigo apresenta uma abordagem baseada em modelos de mistura gaussiana otimizados por inferência bayesiana (BGMMO-CE) para a geração de dados sintéticos em larga escala, útil para ensaios clínicos in silico.

- **Métricas de Medição:**

As métricas incluem Variação Coeficiente (cV), Goodness of Fit (GOF), Divergência de Kullback-Leibler (KLD) e Correlação Cruzada (CC), que avaliam a precisão e a confiabilidade dos dados sintéticos gerados em comparação com os dados reais.

Artigo 41: “**Synthea Novel coronavirus (COVID-19) model and synthetic data set**”

- **Visão Geral da Introdução:**

A introdução descreve o uso de dados sintéticos como uma alternativa segura à desidentificação para compartilhar dados de saúde realísticos, mas não reais. A abordagem utilizando máquinas de transição de estado para gerar esses conjuntos de dados busca garantir a privacidade sem comprometer a utilidade. Métricas como GOF, CC, KS test e CS test são aplicadas para validar a autenticidade e a aplicabilidade dos dados sintéticos em pesquisas de saúde.

- **Abordagens Estatísticas/Algoritmos Usados:**

Este artigo utiliza máquinas de transição de estado para gerar conjuntos de dados sintéticos destinados a estudos de COVID-19, visando manter a privacidade sem sacrificar a utilidade dos dados.

- **Métricas de Medição:**

As métricas aplicadas são Goodness of Fit (GOF), Correlação Cruzada (CC), teste de Kolmogorov-Smirnov (KS test) e teste de Cramér-von Mises (CS test), focadas em medir a aderência e a precisão dos dados sintéticos em relação aos dados reais.

Artigo 45: “**An evaluation of the replicability of analyses using synthetic health data**”

- **Visão Geral da Introdução:**

A introdução foca na utilização de dados sintéticos para permitir um compartilhamento mais amplo de dados de saúde para pesquisa e análise. Através de técnicas como árvores de decisão sequenciais e GANs, o artigo explora como os dados sintéticos podem ser replicáveis em estudos analíticos. A métrica BEC é crucial para avaliar se as análises realizadas com dados sintéticos podem ser replicadas com precisão quando comparadas aos dados reais.

- **Abordagens Estatísticas/Algoritmos Usados:**

Emprega uma árvore de decisão sequencial e redes adversárias generativas (GANs) para criar dados sintéticos em saúde.

- **Métricas de Medição:**

A métrica principal utilizada é a Equivalência Baseada em Evidência (BEC), que verifica se os resultados de análises feitas com dados sintéticos são replicáveis quando comparados com dados reais.

Artigo 51: “SD-GAN: A Style Distribution Transfer Generative Adversarial Network for Covid-19 Detection Through X-Ray Images”

- **Visão Geral da Introdução:**

A introdução aborda o desafio de detectar COVID-19 através de imagens de raio-X, utilizando uma rede adversária generativa de transferência de estilo (SD-GAN) para superar as variações de estilo entre imagens de diferentes centros. Métricas como PSNR e SSIM são utilizadas para avaliar a qualidade visual dos dados sintéticos gerados, garantindo que eles mantenham a fidelidade em relação aos originais e ofereçam uma detecção precisa de COVID-19.

- **Abordagens Estatísticas/Algoritmos Usados:**

Utiliza uma rede adversária generativa de transferência de distribuição de estilo (SD-GAN) para detectar COVID-19 em imagens de raio-X.

- **Métricas de Medição:**

As métricas usadas são a Razão Sinal-Ruído de Pico (PSNR) e o Índice de Similaridade Estrutural (SSIM), que avaliam a qualidade visual dos dados sintéticos gerados em relação aos originais.

Artigo 57: "medigan: a Python library of pretrained generative models for medical image synthesis"

- **Visão Geral da Introdução:**

A introdução discute como a síntese de dados sintéticos pode ajudar a superar desafios como a escassez de dados e a privacidade em aplicações médicas. Utiliza uma variedade de modelos GANs para gerar imagens médicas de alta qualidade. A métrica FID é aplicada para garantir que as imagens sintéticas mantenham a qualidade visual comparável aos dados reais, facilitando assim sua aplicabilidade em contextos clínicos.

- **Abordagens Estatísticas/Algoritmos Usados:**

Este artigo explora o uso de várias redes adversárias generativas (GANs) como CDGAN, CycleGAN, WGAN-GP, C-DCGAN, PGGAN, FastGAN, SinGAN, e pix2pix para a síntese de imagens médicas. Esses modelos são utilizados para superar desafios como a escassez de dados, a adaptação de domínio e a privacidade dos dados.

- **Métricas de Medição:**

A métrica utilizada para medir a qualidade das imagens sintéticas geradas é a Distância de Incepção Fréchet (FID), que avalia a semelhança entre as distribuições das imagens reais e as sintéticas, focando na preservação da qualidade visual.

Artigo 50: "Evaluating the Clinical Realism of Synthetic Chest X-Rays Generated Using Progressively Growing GANs"

- **Visão Geral da Introdução:**

Este artigo aborda o uso de GANs Progressively Growing para criar imagens de raio-X do tórax. Essas imagens são avaliadas não apenas pela FID para a qualidade visual, mas também por avaliações perceptuais humanas para determinar seu realismo clínico. Isso permite que os modelos gerem dados que podem efetivamente imitar variações patológicas reais, promovendo melhorias em diagnósticos automatizados.

- **Abordagens Estatísticas/Algoritmos Usados:**

Utiliza a metodologia de GANs de Crescimento Progressivo (Progressively Growing GANs) para gerar imagens de raio-X de tórax sintéticas com alta resolução. Este método é destacado pela sua capacidade de gerar dados sintéticos altamente realistas e úteis para diagnósticos radiológicos.

- **Métricas de Medição:**

As métricas incluem a Distância de Incepção Fréchet (FID) e avaliações perceptuais humanas (Human eYe Perceptual) para julgar a qualidade das imagens sintéticas e sua viabilidade para uso clínico.

Artigo 26: "GAN-based one dimensional medical data augmentation"

- **Visão Geral da Introdução:**

A introdução explora o uso do WGAN-GP para a geração de dados médicos unidimensionais, como características radiômicas, visando superar a limitação de dados em casos de doenças raras. A métrica t-SNE é utilizada para visualizar a eficácia com que o modelo consegue replicar a distribuição dos dados reais, ajudando na validação da qualidade dos dados sintéticos gerados.

- **Abordagens Estatísticas/Algoritmos Usados:**

Discute o uso do Wasserstein GAN com Gradient Penalty (WGAN-GP) para aumentar dados médicos unidimensionais, como características radiômicas. O algoritmo foca em preservar as características essenciais dos dados originais enquanto gera novos exemplos.

- **Métricas de Medição:**

A métrica utilizada é t-SNE, uma técnica de redução de dimensionalidade que é usada para visualizar a distribuição e a separação dos dados sintéticos e reais, ajudando a entender como o modelo preserva as propriedades dos dados originais.

Artigo 72: "Generating multivariate time series with COmmon Source Coordinated GAN (COSCI-GAN)"

- **Visão Geral da Introdução:**

O artigo introduz o COSCI-GAN, projetado para gerar séries temporais multivariadas que mantêm correlações complexas entre canais de dados. As métricas, como MAE, WD, e outras, são usadas para assegurar que os dados sintéticos preservem as propriedades estatísticas dos dados originais, tornando-os úteis para análises preditivas e diagnósticos.

- **Abordagens Estatísticas/Algoritmos Usados:**

Este artigo apresenta o COSCI-GAN, um método para gerar séries temporais multivariadas que preserva correlações complexas entre diferentes canais de dados. Este modelo é particularmente adequado para dados biométricos e financeiros onde tais correlações são cruciais.

- **Métricas de Medição:**

As métricas incluem Erro Absoluto Médio (MAE), Distância de Wasserstein (WD), Norma de Frobenius, Correlação de Spearman (SC), e Coeficiente de Correlação de Kendall (KRC), focando na preservação das propriedades estatísticas e na utilidade dos dados sintéticos.

Artigo 92: "Natural language generation for electronic health records"

- **Visão Geral da Introdução:**

Aborda a geração de texto natural em registros de saúde eletrônicos usando modelos LSTM. As métricas de desempenho de classificação e previsão, juntamente com a COR, são utilizadas para avaliar como o texto gerado reflete informações reais e mantém a privacidade dos pacientes, resolvendo desafios de compartilhamento de dados em pesquisas médicas.

- **Abordagens Estatísticas/Algoritmos Usados:**

Explora modelos baseados em redes neurais recorrentes Long Short-Term Memory (LSTM) para a geração de texto natural em registros de saúde eletrônicos (EHR). Esses modelos são utilizados para gerar dados sintéticos que imitam registros reais, mantendo a privacidade dos pacientes.

- **Métricas de Medição:**

As métricas são baseadas em desempenho de classificação e métricas de previsão, junto com a Correlação de Ordens (COR), para avaliar a eficácia dos textos sintéticos gerados em replicar informações reais e úteis dos EHR.

Tabela destacando o escopo, abordagens estatísticas, frameworks utilizados e métricas de avaliação dos artigos

Estudo	Escopo	Abordagens Estatísticas/ Algoritmo(s) Usado(s)	Framework s Utilizados	Métricas Usadas para Medir a Fidelidade/Privacidade dos Dados Sintéticos
A computational pipeline for data augmentation towards the improvement of disease classification and risk stratification models	Geração de dados virtuais para melhorar a classificação de doenças e a estratificação de riscos	Modelos Bayesianos, Árvores de decisão, Redes neurais artificiais com funções de base radial (RBF)	Scikit-learn, TensorFlow, PyTorch	Goodness of Fit (GOF), Divergência de Kullback-Leibler (KLD), Correlação Cruzada (CC)
Bayesian Inference-Based Gaussian Mixture Models With	Geração de dados sintéticos para ensaios clínicos in silico	Modelos de mistura gaussiana otimizados por inferência	Scikit-learn, TensorFlow	Varição Coeficiente (cV), GOF, KLD, CC

Optimal Components Estimation Towards Large-Scale Synthetic Data Generation for In Silico Clinical Trials		bayesiana (BGMM-OC E)		
Synthea Novel coronavirus (COVID-19) model and synthetic data set	Geração de dados sintéticos de saúde para estudos de COVID-19	Máquinas de transição de estado	Custom (Synthea framework)	GOF, CC, Teste de Kolmogorov-Smirnov (KS), Teste de Cramér-von Mises (CS)
An evaluation of the replicability of analyses using synthetic health data	Analisar a replicabilidade e de estudos com dados sintéticos em saúde	Árvores de decisão sequenciais, GANs	TensorFlow, PyTorch	Equivalência Baseada em Evidência (BEC)
SD-GAN: A Style Distribution Transfer Generative Adversarial Network for Covid-19 Detection Through X-Ray Images	Detectar COVID-19 em imagens de raio-X utilizando variação de estilo entre centros	SD-GAN	TensorFlow, PyTorch	Razão Sinal-Ruído de Pico (PSNR), Índice de Similaridade Estrutural (SSIM)
medigan: a Python	Geração de imagens	CDGAN, CycleGAN,	TensorFlow, PyTorch	Distância de Incepção Fréchet (FID)

library of pretrained generative models for medical image synthesis	médicas de alta qualidade utilizando GANs	WGAN-GP, C-DCGAN, PGGAN, FastGAN, SinGAN, Pix2Pix		
Evaluating the Clinical Realism of Synthetic Chest X-Rays Generated Using Progressivel y Growing GANs	Avaliar o realismo clínico de imagens de raio-X geradas sinteticamen te	GANs de Crescimento Progressivo	TensorFlow, PyTorch	FID, Avaliações perceptuais humanas (Human eYe Perceptual)
GAN-based one dimensional medical data augmentatio n	Aumentar dados médicos unidimensio nais, como característic as radiômicas	WGAN-GP	TensorFlow, PyTorch	t-SNE
Generating multivariate time series with COMmon Source CoordInated GAN (COSCI-GA N)	Geração de séries temporais multivariada s com correlações complexas	COSCI-GAN	TensorFlow, PyTorch	MAE, Distância de Wasserstein (WD), Norma de Frobenius, Correlação de Spearman (SC), Coeficiente de Correlação de Kendall (KRC)
Natural language generation for electronic health	Geração de texto natural para registros de saúde	LSTM (Redes Neurais Recorrentes)	TensorFlow, PyTorch	Métricas de classificação e previsão, Correlação de Ordens (COR)

records	eletrônicos (EHRs)			
---------	-----------------------	--	--	--

Referências

EMAM, Khaled El (ed.). **Accelerating AI with Synthetic Data**: Generating Data for AI Projects. Estados Unidos: o'reilly, 2020. *E-book* (64p.) color. ISBN: 978-1-492-04596-0.

Disponível em:
https://www.nvidia.com/content/dam/en-zz/Solutions/deep-learning/resources/accelerating-ai-with-synthetic-data-ebook/accelerating-ai-with-synthetic-data-nvidia_web.pdf. Acesso em: 15 set. 2024.

EL EMAM, K. et al. An evaluation of the replicability of analyses using synthetic health data. *Scientific reports*, v. 14, n. 1, p. 6978, 2024. Acesso em: 10 set. 2024.

LEE, S. H. Natural language generation for electronic health records. *npj digital medicine*, v. 1, n. 1, p. 63, 2018. Acesso em: 10 set. 2024.

OSUALA, R. et al. medigan: a Python library of pretrained generative models for medical image synthesis. *Journal of medical imaging (Bellingham, Wash.)*, v. 10, n. 6, p. 061403, 2023. Acesso em: 10 set. 2024.

PEZOULAS, V. C. et al. A computational pipeline for data augmentation towards the improvement of disease classification and risk stratification models: A case study in two clinical domains. *Computers in biology and medicine*, v. 134, n. 104520, p. 104520, 2021. Acesso em: 11 set. 2024.

PEZOULAS, V. C. et al. Bayesian inference-based Gaussian mixture models with optimal components estimation towards large-scale synthetic data generation for in silico clinical trials. *IEEE open journal of engineering in medicine and biology*, v. 3, p. 108–114, 2022. Acesso em: 11 set. 2024.

SD-GAN: A Style Distribution Transfer Generative Adversarial Network for Covid-19 Detection Through X-Ray Images. [s.l: s.n.]. Acesso em: 11 set. 2024.

SEGAL, B. et al. Evaluating the clinical realism of synthetic chest X-rays generated using progressively growing GANs. SN computer science, v. 2, n. 4, p. 321, 2021. Acesso em: 13 set. 2024.

SEYFI, A.; RAJOTTE, J.-F.; NG, R. T. Generating multivariate time series with COmmon Source CoordInated GAN (COSCI-GAN). 2022. Disponível em: <<http://arxiv.org/abs/2205.13741>>. Acesso em: 13 set. 2024.

WALONOSKI, J. et al. Synthea™ Novel coronavirus (COVID-19) model and synthetic data set. Intelligence-based medicine, v. 1, n. 100007, p. 100007, 2020. Acesso em: 13 set. 2024.

ZHANG, Y. et al. GAN-based one dimensional medical data augmentation. Soft computing, 2023. Acesso em: 16 set. 2024.

APÊNDICE 2

Termo de Aceite de Entrega

Objetivo deste documento

Este documento faz parte do Processo da disciplina Residência em IA e tem como objetivo formalizar o aceite da entrega considerando o planejado e o realizado para o período.

Data da Reunião (“gate”) de aprovação: 3 de out. de 2024

Participantes da Entrega [matriculados em Residência em IA]:

Luan Gabriel Silva Oliveira

Entrega: [descrever a ENTREGA: requisitos e produtos gerados: links para textos, códigos, vídeos etc.]

Seleção criteriosa de artigos científicos

- Exclusão de estudos focados em geração de Dados Sintéticos na área da Saúde;
 - Foco de aplicações em Robótica, Segurança e Simulação
- Priorização de artigos que abordam métodos de implementação como Deep Learning, Machine Learning e Visão Computacional.
 - Detalhamento das ferramentas e frameworks utilizados
 - GANs e CNNs
- Entendimento do objetivo do estudo
 - O que ele se propôs a resolver (Como os dados sintéticos se encaixam nesse problema)?
 - Como ele aborda o problema (De que maneira os dados sintéticos são gerados)?

Estudo realizado: [Estudo_Artigos](#)

Utilização da ferramenta [ResearchRabbit.ai](https://researchrabbit.ai) para buscar artigos científicos relacionados ao tema delimitado

- Possibilidade de encontrar artigos relacionados/similares aos artigos selecionados na busca;
- Artigos selecionados e filtrados seguindo o objetivo da busca

Artigos selecionados: [Artigos_Selecionados](#)

Planejamento: [descrever o que pretende fazer para realizar a próxima ENTREGA]

Estudar de maneira mais específica os modelos: GANs e CNNs e suas aplicações em Dados Sintéticos

- Focar em aplicações que geram Dados Sintéticos
- Como cada arquitetura é utilizada para implementar Dados sintéticos nas diferentes áreas de aplicação
 - Ferramentas, Frameworks e Bibliotecas

Observação: [caso precise fazer alguma observação, de qualquer “natureza”]

ACEITE DA ENTREGA:

CEDRIC LUIZ DE CARVALHO: Go! ▾

Screening dos Artigos selecionados:

O artigo "**Machine Learning for Synthetic Data Generation: A Review**" oferece uma visão do estado atual da geração de dados sintéticos usando modelos de aprendizado de máquina, com foco particular em redes neurais e modelos generativos profundos.

O artigo começa destacando a importância dos dados para o aprendizado de máquina e os desafios enfrentados devido à qualidade dos dados, privacidade e escassez de dados. Ele explora o conceito de dados sintéticos como uma alternativa promissora que permite a utilização e compartilhamento de dados de maneiras que os dados reais não permitem.

Por fim, revisa estudos existentes que empregam modelos de aprendizado de máquina para geração de dados sintéticos em diversos domínios, como visão computacional, processamento de linguagem natural, saúde e negócios.

Ferramentas e Frameworks Utilizados

Modelos Generativos Profundos: Várias arquiteturas de rede neural são exploradas para a geração de dados sintéticos de alta qualidade, com ênfase especial em modelos generativos como as Generative Adversarial Networks (GANs), Variational Autoencoders (VAEs) e modelos de difusão.

Redes Neurais: Diferentes arquiteturas de redes neurais são discutidas, incluindo redes neurais convolucionais (CNNs) para dados de imagem, redes neurais recorrentes (RNNs) para dados sequenciais, e redes neurais baseadas em grafos (GNNs) para dados que possuem uma estrutura de grafo inerente.

Problemas Abordados

Privacidade e Justiça: O artigo trata das preocupações com privacidade e justiça relacionadas à geração de dados sintéticos, discutindo métodos para criar conjuntos de dados anonimizados com proteções de privacidade diferencial.

Superando a Escassez de Dados: Uma aplicação significativa da geração de dados sintéticos é superar a limitação da escassez de dados, permitindo um treinamento mais eficaz e generalizável de modelos de aprendizado de máquina.

Redução de Riscos de Privacidade: Os dados sintéticos podem reduzir os riscos de exposição de informações sensíveis, garantindo segurança e privacidade dos clientes.

O artigo "**Object Detection and Pose Estimation based on Convolutional Neural Networks Trained with Synthetic Data**" oferece uma abordagem para detecção de objetos e estimativa de pose 3D usando redes neurais convolucionais (CNNs) treinadas com dados sintéticos.

Introdução e Trabalhos Relacionados

O artigo aborda o desafio de detecção de objetos e estimativa de pose em ambientes não controlados usando CNNs, destacando que enquanto as abordagens tradicionais são precisas, dependem de condições controladas e texturas detalhadas dos objetos, o que limita sua aplicabilidade em tarefas robóticas reais.

Ferramentas e Frameworks Utilizados

CNNs: Usadas devido à sua capacidade de aprender características hierárquicas discriminativas diretamente dos dados de treinamento.

Blender: Utilizado para gerar dados de treinamento sintéticos, simulando diferentes condições de iluminação e posições dos objetos.

Faster R-CNN: Adotado para detectar e classificar regiões da imagem, onde cada região identificada é então processada para estimativa de pose usando um modelo específico de CNN.

Arquitetura VGG-16: Utilizada na parte convolucional do modelo de estimativa de pose, conhecida por sua eficácia em tarefas de classificação de imagens e adaptação a outros contextos.

Problema Abordado

O artigo propõe-se resolver o problema de detecção de objetos e estimativa de pose em ambientes não controlados usando apenas dados sintéticos para treinamento. Ele testa a hipótese de que é possível treinar modelos eficazes com dados sintéticos que podem ser generalizados para imagens reais, um aspecto crucial para aplicações em robótica, como no manuseio e na interação com objetos.

Insights e Conclusões

- O modelo mostrou ser capaz de generalizar dados sintéticos para imagens reais, o que é significativo para a implementação prática em robótica.
- A combinação de detecção de objetos e estimativa de pose utilizando um framework de CNN demonstrou ser uma estratégia promissora para superar as limitações dos métodos tradicionais que requerem condições altamente controladas.

O artigo "**Synthetic Data Generation for the Internet of Things**" apresenta um framework para a geração de dados sintéticos destinados a pesquisas sobre a Internet das Coisas (IoT), enfocando especialmente a proteção de dados privados e propriedade intelectual. Aqui estão os insights mais relevantes do artigo:

Introdução e Trabalhos Relacionados

O artigo discute o crescente papel dos dispositivos IoT em nossas vidas e as dificuldades associadas ao gerenciamento de dados IoT, que são frequentemente grandes, complexos e desestruturados. A geração de dados sintéticos é proposta como solução para realizar pesquisas sem comprometer dados proprietários ou privados.

Ferramentas e Frameworks Utilizados

Framework de Geração de Dados Sintéticos: Desenvolvido para gerar dados que imitam as características estruturais e estatísticas dos dados originais, sem comprometer informações proprietárias ou pessoais.

Hadoop MapReduce: Utilizado para processar e analisar grandes volumes de dados de entrada, facilitando a escala e a eficiência do processamento de dados.

XML/JSON: Formatos usados para lidar com dados não estruturados ou semi-estruturados típicos de aplicações IoT.

Problema Abordado

O artigo visa resolver o problema de como realizar pesquisas significativas em infra estruturas de dados de grandes empresas sem expor dados sensíveis ao risco. Isto é abordado através da criação de dados sintéticos que podem ser usados em ambientes de teste e pesquisa externos.

Conclusão e Insights

A capacidade de gerar grandes volumes de dados sintéticos que retêm as características essenciais dos conjuntos de dados originais permite experimentações e desenvolvimento fora do ambiente de produção, sem riscos de segurança. Isso é crucial para empresas que lidam com grandes quantidades de dados sensíveis.

O artigo "**Synthetic Data Generation for Steel Defect Detection and Classification Using Deep Learning**" descreve uma metodologia para treinar redes neurais para tarefas de visão computacional usando dados sintéticos, focando na detecção e classificação de defeitos em chapas de aço.

Introdução e Trabalhos Relacionados

O artigo aborda a necessidade de grandes conjuntos de dados rotulados para treinar algoritmos de aprendizado de máquina, especialmente em sistemas de automação industrial onde os dados de produção podem ser insuficientes ou inadequados. Nesse sentido, ele destaca a utilização de dados sintetizados como uma solução para acelerar a coleta e a anotação de dados de treinamento, citando aplicações similares em veículos autônomos e diagnósticos de câncer.

Ferramentas e Frameworks Utilizados

Blender: Usado para gerar o conjunto de treinamento. Blender é um editor 3D que possui ferramentas integradas necessárias para a geração programática de texturas de defeitos em chapas de aço.

Redes Neurais: Unet para segmentação de defeitos e Xception para classificação foram treinadas usando dados sintéticos.

Keras e Python: Utilizados para treinamento e avaliação de modelos de redes neurais.

Problema Abordado

O artigo foca na criação de conjuntos de dados sintéticos para superar a falta de dados de treinamento de alta qualidade e detalhados necessários para treinar modelos de visão computacional em sistemas de inspeção de superfície de chapas de aço.

Conclusão e Insights

- Os modelos treinados com dados sintéticos mostraram bons resultados na classificação e segmentação de defeitos, validados contra um conjunto de dados real, o que demonstra a viabilidade do uso de dados sintéticos para treinamento em contextos industriais.
- Este estudo ilustra como a geração de dados sintéticos pode ser uma ferramenta poderosa para desenvolver e testar sistemas de controle de qualidade automáticos, especialmente quando o acesso a grandes quantidades de dados anotados é restrito.

O livro "**Digital Processing of Synthetic Aperture Radar Data: Algorithms and Implementation**" abrange uma ampla gama de técnicas e metodologias para o processamento de dados de radar de abertura sintética (SAR), com um foco especial na geração de dados sintéticos. Aqui estão os pontos principais do livro com base nos trechos acessados:

Introdução e Fundamentos de SAR

O livro começa com uma introdução ao radar de abertura sintética (SAR), destacando sua importância em sensoriamento remoto e suas aplicações em monitoramento ambiental e mapeamento terrestre. Além disso, ele explora os fundamentos do SAR, incluindo os princípios básicos de funcionamento, a geometria dos sistemas SAR e a importância do processamento de sinal para a geração de imagens de alta qualidade.

Processamento de Sinal e Algoritmos SAR

Discussão detalhada sobre os fundamentos do processamento de sinais, como convolução, transformadas de Fourier e técnicas de amostragem, que são cruciais para entender como os sinais SAR são processados para gerar imagens. O livro explora diversos algoritmos para processamento de dados SAR, incluindo o Range-Doppler Algorithm, Chirp Scaling

Algorithm e o Omega-K Algorithm, explicando como cada um contribui para a melhoria da qualidade das imagens SAR.

Geração de Dados Sintéticos e Aplicações

Um tema recorrente é a utilização de dados sintéticos para aprimorar algoritmos de processamento SAR. A geração de dados sintéticos é abordada como uma solução para superar a falta de dados reais, especialmente em aplicações onde a coleta de dados é desafiadora ou cara. Outrossim, são discutidas as técnicas para criar dados sintéticos que imitam as propriedades dos sinais reais capturados por sistemas SAR, permitindo assim um desenvolvimento e teste de algoritmos mais eficiente e menos dependente de condições de campo.

Implementação e Avaliação de Algoritmos

O livro também foca na implementação prática dos algoritmos em hardware e software, discutindo as considerações necessárias para realizar o processamento de dados SAR em tempo real e com alta eficiência. Ele realiza uma avaliação de desempenho dos algoritmos usando dados sintéticos e reais, com uma análise de como diferentes abordagens de processamento afetam a acurácia e a eficácia das imagens SAR geradas.

O artigo "**A Deep Representation for Depth Images from Synthetic Data**" explora o uso de dados sintéticos para treinar redes neurais convolucionais (CNNs) específicas para a análise de imagens de profundidade (2.5D). Aqui estão os detalhes relevantes com base na sua solicitação:

Introdução e Trabalhos Relacionados

O artigo discute a utilização de CNNs, treinadas originalmente em grandes bancos de dados RGB como o ImageNet, para categorização de objetos usando dados RGB-D. O desafio abordado é que as imagens de profundidade são perceptualmente diferentes das imagens RGB, destacando-se mais pelas silhuetas dos objetos do que por texturas. O artigo destaca

a falta de um grande banco de dados de imagens de profundidade adequado para treinar CNNs especificamente para esse tipo de dado.

Ferramentas e Frameworks Utilizados

Blender: Usado para gerar imagens de profundidade a partir de modelos CAD 3D.

CaffeNet: Uma arquitetura de rede neural leve baseada no AlexNet, utilizada para treinar as CNNs com as imagens de profundidade sintéticas geradas.

VANDAL Database: Um banco de dados criado pelos autores, contendo 4.1 milhões de imagens de profundidade de mais de 9.000 objetos em 319 categorias, geradas sinteticamente.

Problema Abordado

O principal problema abordado é a falta de um grande conjunto de dados de imagens de profundidade para treinar redes neurais eficazes para a categorização de objetos em imagens 2.5D. Os autores propõem uma solução alternativa, criando um grande conjunto de dados sintéticos, o VANDAL, para treinar CNNs que podem extrair características específicas das imagens de profundidade.

Abordagem e Resultados Experimentais

A abordagem consiste em usar o banco de dados VANDAL para treinar uma CNN do zero, criando um modelo pré-treinado que atua como um extrator de características específicas para imagens de profundidade. Os resultados experimentais mostram que as características aprendidas são capazes de capturar diferentes facetas das imagens de profundidade e são complementares às características derivadas de CNNs pré-treinadas em datasets 2D.

O artigo "**Learning Object Localization and 6D Pose Estimation from Simulation and Weakly Labeled Real Images**" aborda a localização de objetos e a estimativa de pose 6D a partir de imagens simuladas e reais fracamente rotuladas. Aqui estão os detalhes mais relevantes:

Introdução e Trabalhos Relacionados

Problema: A estimativa de pose precisa é crucial para a manipulação robótica robusta em ambientes desordenados e apertados. A necessidade de grandes volumes de dados de treinamento rotulados é um grande desafio devido ao custo e esforço necessários para obter dados de pose de 6 graus de liberdade precisos.

Abordagem: Propõe uma arquitetura e um processo de treinamento que utiliza uma combinação de imagens sintéticas e um pequeno número de imagens reais fracamente rotuladas para minimizar o esforço humano em anotações.

Ferramentas e Frameworks Utilizados

- **Geração de Dados Sintéticos:** Utilização de modelos CAD renderizados em diversos fundos para gerar imagens sintéticas.
- **Treinamento de CNNs:** Uso de redes neurais convolucionais para detectar e localizar objetos e estimar suas poses em 6D.
- **Domain Adaptation:** Emprego de classificadores de domínio treinados de forma adversarial para minimizar a discrepância entre imagens reais e sintéticas.
- **Stochastic Congruent Sets (StoCS):** Uma técnica de estimativa de pose independente utilizada durante a fase de inferência para refinar as estimativas de pose baseadas em mapas de calor específicos da classe gerados pela rede.

Problema Abordado

O artigo aborda a complexidade de treinar modelos de visão computacional para realizar tarefas de localização de objetos e estimativa de pose em 6D em cenários onde as anotações detalhadas são escassas ou caras de obter, especialmente em ambientes de automação de armazéns.

Metodologia Proposta

Weakly Supervised Learning: Redução significativa no esforço de anotação por meio do aprendizado supervisionado fraco, usando apenas listas de objetos presentes nas imagens sem anotações demoradas como caixas delimitadoras ou máscaras de segmentação.

Adaptação de Domínio e Aprendizado Semi-Supervisionado: Ajuste fino da rede em um pequeno conjunto de imagens reais fracamente rotuladas para melhorar a generalização do aprendizado de um domínio sintético para um real.

O artigo "**DECAF: Generating Fair Synthetic Data Using Causally-Aware Generative Networks**" aborda a criação de dados sintéticos justos através de redes gerativas que incorporam conhecimento causal. Aqui estão os detalhes mais relevantes:

Introdução e Trabalhos Relacionados

A necessidade de gerar dados sintéticos justos que não reflitam os vieses presentes nos dados originais, permitindo que modelos treinados com esses dados sejam justos, independentemente do algoritmo de aprendizado usado posteriormente. Ademais, o artigo revisa diversos trabalhos relacionados à geração de dados sintéticos e à detecção/remoção de viés, destacando lacunas como a falta de métodos que permitam alterações pós-hoc nas distribuições sintéticas para atender a diferentes concepções de justiça.

Ferramentas e Frameworks Utilizados

DECAF (DEbiasing CAusal Fairness): Uma rede GAN que incorpora estruturas causais na geração de dados, permitindo a remoção intencional de viés nos dados sintéticos gerados.

Modelos Causais: O uso de modelos causais como parte da arquitetura da rede permite que intervenções específicas sejam feitas nas variáveis durante a geração de dados para garantir a justiça.

Metodologia Proposta

Geração de Dados Justos: DECAF utiliza uma abordagem baseada em conhecimento causal para modificar dados sintéticos de forma que eles atendam a requisitos de justiça específicos, removendo "arestas" que representam relações causais injustas.

Avaliação de Justiça: O framework é compatível com várias definições de justiça e mostra como dados sintéticos podem ser ajustados para atender a diferentes padrões de justiça, como paridade demográfica e justiça condicional.

Experimentos e Resultados

Experimentos realizados no artigo demonstram que o DECAF pode remover viés indesejado dos dados, mantendo ao mesmo tempo a utilidade dos dados para o treinamento de modelos.

Referências

ANDERSON, J. W. et al. Synthetic data generation for the internet of things. 2014 IEEE International Conference on Big Data (Big Data). Anais...IEEE, 2014.

BOIKOV, A. et al. Synthetic data generation for steel Defect Detection and classification using deep learning. Symmetry, v. 13, n. 7, p. 1176, 2021.

CARLUCCI, F. M.; RUSSO, P.; CAPUTO, B. A deep representation for depth images from synthetic data. 2017 IEEE International Conference on Robotics and Automation (ICRA). Anais...IEEE, 2017.

JOSIFOVSKI, J. et al. Object detection and pose estimation based on convolutional neural networks trained with synthetic data. 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Anais...IEEE, 2018.

LU, Y. et al. Machine learning for synthetic data generation: A review. 2023. Disponível em: <<http://arxiv.org/abs/2302.04062>>.

MERCIER, J.-P. et al. Learning object localization and 6D pose estimation from simulation and weakly labeled real images. 2019 International Conference on Robotics and Automation (ICRA). Anais...IEEE, 2019.

VAN BREUGEL, B. et al. DECAF: Generating fair synthetic data using causally-aware generative networks. 2021. Disponível em: <<http://arxiv.org/abs/2110.12884>>.

APÊNDICE 3

Termo de Aceite de Entrega

Objetivo deste documento

Este documento faz parte do Processo da disciplina Residência em IA e tem como objetivo formalizar o aceite da entrega considerando o planejado e o realizado para o período.

Data da Reunião (“gate”) de aprovação: 9 de out. de 2024

Participantes da Entrega [matriculados em Residência em IA]:

Luan Gabriel Silva Oliveira

Entrega: [descrever a ENTREGA: requisitos e produtos gerados: links para textos, códigos, vídeos etc.]

Estudo comparativo do processo de geração de dados sintéticos: GANs vs CNNs

- Seleção de artigos novos e já abordados que utilizam GANs ou CNNs para a geração de dados sintéticos
 - Estudo robusto dos tipos de dados gerados para cada modelo
 - Métodos de geração/Processamento
 - Vantagens e desvantagens

Documentação realizada: [Estudo comparativo GANs e CNNs](#)

Criação de duas tabelas comparando características principais dos métodos de geração de dados sintéticos com GANs e CNNs

- Análise de aspectos relevantes para o processo de implementação das GANs e CNNs
- Insight sobre a integração das duas redes
 - Problema da Adaptação de Domínio
- Tabela apresentando vantagens e desvantagens de características relevantes no processo de integração de GANs e CNNs
 - Complexidade e Sinergia
 - Inovação e Escalabilidade

Arquivo com as tabelas criadas: [Tabelas comparação/Integração](#)

Planejamento: [descrever o que pretende fazer para realizar a próxima ENTREGA]

Continuar os estudos referentes a integração de GANs e CNNs nos diversos cenários de aplicação

- Como realizar essa integração
- Quais tipos de Dados Sintéticos é possível gerar (Multimodalidade)

Observação: [caso precise fazer alguma observação, de qualquer “natureza”]

ACEITE DA ENTREGA:

CEDRIC LUIZ DE CARVALHO: Go! ▾

GANs para Geração de Dados Sintéticos

Tipos de Dados Gerados:

Imagens Médicas: As GANs são utilizadas para gerar dados médicos sintéticos que ajudam na formação e validação de algoritmos de diagnóstico médico sem comprometer a privacidade dos pacientes. Por exemplo, no artigo sobre a geração de imagens sintéticas de ultrassom, as GANs foram usadas para criar imagens de ultrassom realistas para treinar modelos de reconhecimento de padrões médicos, possibilitando o treinamento sem acesso direto a dados sensíveis de pacientes.

Imagens Subaquáticas: Em aplicações marítimas, como explorado em um dos artigos, as GANs transformam imagens aéreas em imagens subaquáticas para ajudar na adaptação de domínio, o que é crucial para pesquisas oceânicas e ambientais sem necessidade de coletas de dados dispendiosas e desafiadoras.

Detecção de Fraudes: Em ambientes financeiros, as GANs são aplicadas para gerar registros transacionais sintéticos para treinar modelos de detecção de fraude, como visto no artigo que aborda a geração de dados sintéticos para detecção de fraude em jogos de azar online.

Vantagens:

Realismo: As GANs são capazes de gerar imagens que replicam de maneira convincente a variação encontrada em cenários do mundo real, tornando-as ferramentas ideais para treinamento e pesquisa sem riscos éticos.

Versatilidade: A tecnologia pode ser adaptada para quase qualquer tipo de dados visuais, demonstrando uma ampla gama de aplicabilidade desde a saúde até contextos ambientais.

Desvantagens:

Dificuldade de Treinamento: Como discutido no contexto da geração de imagens de tumores cerebrais, as GANs exigem ajustes finos e um entendimento profundo de suas dinâmicas para evitar problemas como o colapso de modo.

CNNs para Aprimoramento e Processamento de Dados Sintéticos

Tipos de Dados Processados:

Detecção de Objetos: CNNs são usadas para melhorar a precisão na detecção de objetos em ambientes complexos, como demonstrado na detecção de veículos usando dados sintéticos em sistemas de assistência ao motorista.

Análise de Imagens: Em um contexto médico, CNNs são empregadas para analisar e melhorar a qualidade das imagens de microscopia geradas por GANs, permitindo uma análise mais precisa em pesquisas científicas.

Vantagens:

Reconhecimento de Características: Sua capacidade de extrair características de imagens complexas as torna indispensáveis em aplicações que vão desde a vigilância até diagnósticos médicos.

Escalabilidade: As CNNs podem ser eficientemente aplicadas a grandes conjuntos de dados, aproveitando suas arquiteturas profundas para processar e analisar grandes volumes de informações.

Desvantagens:

Dependência de Dados Rotulados: O treinamento de CNNs requer uma grande quantidade de dados rotulados, o que pode ser um desafio em domínios onde os dados rotulados são escassos ou difíceis de obter.

Generalização: Há desafios em generalizar os aprendizados de dados sintéticos para aplicações do mundo real, especialmente se os dados gerados não capturarem toda a variação dos dados naturais.

Tabela comparativa: Implementação de Dados Sintéticos - GANs vs CNN

Característica	GANs	CNNs
Tipo de modelo	Modelo generativo que aprende a criar dados que imitam a distribuição de um conjunto de dados real	Modelo discriminativo usado principalmente para classificação e reconhecimento de padrões em dados

Metodologia utilizada	Baseia-se em um jogo teórico entre duas redes, o gerador (cria dados) e o discriminador (avalia dados)	Utiliza camadas convolucionais para processar dados de entrada em uma estrutura hierárquica para reconhecimento de padrões
Complexidade de treinamento	Alta, devido à necessidade de balancear o treinamento do gerador e do discriminador para evitar o colapso de modo	Relativamente mais baixa comparada às GANs, embora a arquitetura possa se tornar complexa dependendo da profundidade e do escopo
Capacidade de Geração	Ótima para gerar novos dados sintéticos, como imagens, textos, e áudio, que podem não existir nos dados reais	Capaz de melhorar ou modificar dados existentes através de técnicas como data augmentation
Aplicações Comuns	Usada em campos que requerem geração de novos conteúdos, como arte digital, desenvolvimento de jogos, e treinamento de IA sem dados reais	Predominantemente usada em visão computacional, análise de imagens médicas e sistemas de vigilância
Vantagens	Capaz de aprender distribuições complexas de dados e gerar dados altamente realistas a partir de pouco ou nenhum dado de entrada	Eficaz em extrair características automaticamente de imagens, o que é útil para tarefas que requerem identificação e categorização precisas
Desvantagens	Pode ser instável durante o treinamento; desafios incluem o colapso de modo, onde o gerador produz limitada diversidade de saídas	Requer grande quantidade de dados rotulados para treinamento efetivo; suscetível a overfitting se não houver regularização adequada
Custo de computacional de Implementação	Alta, devido à necessidade de recursos computacionais significativos para treinar	Variável; geralmente menor que GANs, mas pode aumentar com redes mais

	modelos estáveis e eficazes.	profundas ou conjuntos de dados mais extensos.
--	------------------------------	--

Integração de GANs e CNNs

Aspecto	Vantagens	Desvantagens
Complementaridade	GANs e CNNs trabalham juntas para melhorar a fidelidade e utilidade dos dados sintéticos. GANs geram novos dados que as CNNs podem usar para treinamento e validação, aumentando a diversidade do conjunto de treinamento e reduzindo a dependência de dados reais caros ou sensíveis	A integração pode ser complexa, pois exige que dois modelos diferentes com objetivos distintos funcionem harmoniosamente, o que pode ser desafiador em termos de sincronização e estabilidade durante o treinamento
Qualidade dos Dados	A validação cruzada entre GANs e CNNs pode ajudar a melhorar a qualidade dos dados gerados, com CNNs atuando como um crivo para verificar e aprimorar os outputs das GANs. Isso pode levar a melhorias significativas na precisão dos modelos treinados com esses dados	Se não configurados corretamente, os dados gerados podem acabar sendo inutilizáveis, com artefatos e características não realistas que podem comprometer o treinamento do modelo
Inovação	A integração fomenta a inovação ao permitir aplicações avançadas como a criação de cenários completamente novos para treinamento de sistemas de IA, o que seria impraticável com dados reais	A pesquisa e desenvolvimento contínuos são necessários para explorar plenamente os benefícios potenciais, o que pode exigir investimentos substanciais em tempo e recursos

Flexibilidade	Permite a exploração de novas áreas de aplicação, adaptando-se a diferentes necessidades e contextos, como simulações médicas, criações artísticas, e testes de segurança em sistemas autônomos	Pode ser desafiador adaptar os modelos para tarefas específicas ou conjuntos de dados incomuns sem uma expertise substancial em ambos os domínios de rede (GAN e CNN)
Eficiência	Aumenta a eficiência ao usar dados sintéticos para treinamento preliminar, reduzindo a necessidade de etiquetagem manual e coleta de novos dados, o que é especialmente útil em domínios com escassez de dados	A geração de dados e o treinamento subsequente podem exigir uma quantidade significativa de poder computacional e capacidade de armazenamento, especialmente para conjuntos de dados grandes e complexos
Escalabilidade	A capacidade de gerar grandes volumes de dados sob demanda pode permitir o escalonamento de aplicações de IA que de outra forma seriam limitadas pela disponibilidade de dados.	O gerenciamento e processamento eficaz desses grandes volumes de dados gerados requer infraestrutura adequada, o que pode ser um obstáculo para organizações com recursos limitados.

Termo de Aceite de Entrega

Objetivo deste documento

Este documento faz parte do Processo da disciplina Residência em IA e tem como objetivo formalizar o aceite da entrega considerando o planejado e o realizado para o período.

Data da Reunião (“gate”) de aprovação: 17 de out. de 2024

Participantes da Entrega [matriculados em Residência em IA]:

Luan Gabriel Silva Oliveira

Entrega: [descrever a ENTREGA: requisitos e produtos gerados: links para textos, códigos, vídeos etc.]

Seleção e análise de artigos com enfoque em integração de GANs e CNNs para Geração de Dados Sintéticos:

- Artigos que apresentam o uso de GANs e CNNs para a geração de dados sintéticos em diversas áreas foram revisados;
- Estudo concentrado em entender como os modelos GANs e CNNs foram integrados nesses artigos, identificando metodologias e aplicações específicas.
 - Foco principal em três vertentes:
 - Como foi realizado o processo de integração dos modelos;
 - Qual tipo de Dado Sintético foi gerado;
 - Possíveis estratégias para replicar as implementações.

Entregável 1: **Análise dos Artigos que integram GANs e CNNs**

Síntese das informações dos artigos:

- Busca por padrões e pontos de convergência na utilização de GANs e CNNs;
- Desenvolvimento de uma estratégia geral para a integração dos modelos na geração de dados sintéticos.
 - Ciclos de feedbacks iterativos
 - Alinhamento de domínio

Entregável 2: **Estratégias para integração de GANs e CNNs Multimodais**

Planejamento: [descrever o que pretende fazer para realizar a próxima ENTREGA]

Continuar os estudos dos artigos referentes ao processo de integração dos modelos, com foco em implementações práticas.

- Tornar mais robusto o entendimento do processo de integração;

- Extrair informações referentes à metodologias mais comuns e que possam servir como exemplo de implementação.

Desenvolver um protótipo simplificado baseado nas estratégias identificadas nos artigos para testar a viabilidade das integrações de GANs e CNNs.

- Utilizar alguma base de dados simples como Fashion MNIST para uma validação inicial.
 - Aplicação de alguns frameworks para efetivar essa integração;
 - Gerar dados sintéticos a partir do dataset escolhido.

Observação: [caso precise fazer alguma observação, de qualquer “natureza”]

ACEITE DA ENTREGA:

CEDRIC LUIZ DE CARVALHO: Go! ▾

Análise dos artigos que integram GANs e CNNs

1. Contagem de Multidões em Condições Climáticas Adversas usando Denoising de Imagem com Pix2Pix GANs

Processo de Integração: O artigo utiliza uma GAN Pix2Pix para remover ruídos de imagens de multidões antes de passá-las para uma CNN para estimativa de densidade. O GAN Pix2Pix é treinado em imagens sintéticas ruidosas geradas a partir de imagens originais de multidões. Após o treinamento, o gerador pré-treinado do Pix2Pix GAN é usado no motor de inferência para pré-processar imagens ruidosas antes de serem alimentadas na CNN para estimativa de densidade de multidão.

Tipo de Dado Gerado: As imagens geradas e processadas são imagens de multidões sob várias condições de ruído, como nevoeiro e poeira, destinadas a simular cenários climáticos adversos.

Estratégia de Implementação: Para replicar isso, seria necessário gerar um conjunto de dados de pares de imagens ruidosas e limpas, treinar um GAN Pix2Pix para remoção de ruído e, em seguida, usar a saída do GAN como entrada para uma CNN que realiza a estimativa de densidade.

2. Melhorando o Diagnóstico de Doenças Oculares com Aprendizado Profundo e Ampliação de Dados Sintéticos

Processo de Integração: O artigo foca em aprendizado conjunto para diagnosticar doenças oculares como retinopatia diabética, ele menciona o uso de GANs para gerar imagens sintéticas de alta qualidade que são usadas para aumentar o conjunto de dados de treinamento para uma CNN.

Tipo de Dado Gerado: Imagens médicas sintéticas, particularmente para doenças oculares.

Estratégia de Implementação: Seria possível gerar imagens sintéticas de doenças oculares usando GANs, garantindo que essas imagens sejam diversas e de alta qualidade, e então usar essas imagens para treinar uma CNN ou um conjunto de CNNs para melhorar a precisão diagnóstica.

3. Estratégias de Amostragem para Dados Sintéticos GAN

Processo de Integração: Este artigo discute o uso de pontuações do discriminador de GANs para amostrar seletivamente dados sintéticos que são mais realistas ou relevantes para o treinamento de CNNs. A ideia é usar essas pontuações para filtrar dados sintéticos menos realistas ou menos úteis antes de usá-los no treinamento da CNN.

Tipo de Dado Gerado: Dados sintéticos genéricos aplicáveis a vários domínios, incluindo atributos faciais.

Estratégia de Implementação: Seria possível implementar um mecanismo para avaliar a qualidade dos dados sintéticos usando as pontuações do discriminador, usando apenas exemplos sintéticos de alta qualidade para treinar sua CNN para garantir que os dados melhorem efetivamente o desempenho do modelo.

4. Geração de Dados Sintéticos com Redes Adversárias Condicionais (Conditional Generative Adversarial Networks - CGANs)

Processo de Integração: Este estudo emprega CGANs para gerar dados sintéticos considerando rótulos de classe, permitindo a criação de dados que são mais específicos e úteis para tarefas de classificação. A integração aqui foca em gerar dados que simulam a distribuição do conjunto de dados original de forma condicionada aos rótulos de classe.

Tipo de Dado Gerado: Dados sintéticos que imitam as características de datasets originais, com aplicações potenciais em ambientes onde os dados são sensíveis ou escassos.

Implementação: Você poderia implementar uma CGAN que utilize informações de classe como condição, treinando-a com dados rotulados para gerar novos exemplos que respeitem as distribuições de classe do conjunto de dados original.

5. Detecção de Objetos Usando CNNs Treinadas em Imagens Sintéticas

Processo de Integração: A pesquisa mostra como redes CNN treinadas com datasets inteiramente sintéticos podem ser aplicadas efetivamente na detecção de objetos, usando uma abordagem de transferência de aprendizado para adaptar o modelo de imagens sintéticas para imagens reais.

Tipo de Dado Gerado: Imagens sintéticas de produtos embalados, usadas para treinar uma CNN para detecção de objetos em cenas de refrigeradores.

Implementação: Gerar um conjunto de dados sintéticos usando técnicas de renderização e usar esses dados para treinar uma CNN, aplicando transferência de aprendizado para adaptar o modelo ao domínio de imagens reais.

6. Segmentação de Tumores Cerebrais Usando Imagens de Ressonância Magnética Sintéticas

Processo de Integração: Este estudo compara GANs e modelos de difusão na geração de imagens sintéticas para treinar redes de segmentação de tumores cerebrais, destacando a utilização de GANs para gerar imagens que são posteriormente usadas para treinar CNNs para segmentação.

Tipo de Dado Gerado: Imagens sintéticas de ressonância magnética (RM) do cérebro para segmentação de tumores.

Implementação: Utilizar GANs para gerar imagens de RM sintéticas e treinar modelos de segmentação, como CNNs, para aprender a identificar e segmentar tumores cerebrais em dados sintéticos antes de aplicar em dados reais.

7. Geração de Dados Sintéticos com Redes Adversárias Condicionais (CGANs)

Processo de Integração: O artigo detalha o uso de CGANs para gerar padrões de difração ideais a partir de imagens de difração experimentais, que são então analisadas por uma CNN para prever alterações de temperatura em amostras de bismuto. Este método melhora a consistência e precisão da CNN ao fornecer dados sintéticos de alta qualidade para treinamento.

Tipo de Dado Gerado: Padrões de difração ideais de bismuto, utilizados para análise estrutural e previsão de temperatura.

Implementação: Para replicar, seria necessário desenvolver um CGAN que transforme imagens de difração reais em padrões ideais, que depois são usados para treinar uma CNN para realizar análises específicas, como previsões de temperatura baseadas em mudanças estruturais observadas nas imagens.

2. AI-Driven Personalized Medicine

Processo de Integração: O artigo discute a utilização de GANs para criar dados sintéticos que ajudam a enriquecer o conjunto de dados para treinamento de CNNs em aplicações médicas personalizadas, como tratamento de câncer. As GANs geram dados que imitam amostras reais de doenças, melhorando a robustez e a precisão das CNNs na previsão de tratamentos personalizados.

Tipo de Dado Gerado: Dados sintéticos relacionados a várias condições médicas, usados para treinar modelos de previsão de tratamento.

Implementação: Implementar GANs para gerar imagens médicas sintéticas que serão utilizadas para treinar CNNs, com o objetivo de melhorar a capacidade de diagnóstico e personalização do tratamento médico.

Estratégias para integração de GANs e CNNs Multimodais

1. Definição de Objetivos e Escopo

Identificação de Necessidades Multimodais: É necessário determinar as modalidades de dados que são essenciais para o projeto, como texto, imagem, som, ou vídeo, e como essas modalidades podem interagir ou complementar uma à outra.

Objetivos Específicos: É necessário definir quais problemas a geração de dados sintéticos pretende resolver, como desequilíbrios em conjuntos de dados, privacidade de dados, ou melhoramento da precisão de modelos de IA.

2. Desenvolvimento de GANs Multimodais

Arquitetura Personalizada: A GANs precisa ser projetada para ser capaz de gerar dados em múltiplas modalidades simultaneamente. Por exemplo, uma GAN que pode gerar tanto a imagem de um objeto quanto a descrição textual correspondente.

Treinamento Sincronizado: Utilizar Frameworks ou técnicas de treinamento que sincronizem a geração de dados entre diferentes modalidades, garantindo que os dados gerados sejam consistentes e complementares entre as modalidades.

3. Utilização de CNNs para Análise e Aprimoramento

Refinamento de Dados Sintéticos: As CNNs devem ser utilizadas para analisar e refinar os dados gerados pelas GANs, assegurando que eles atendam aos critérios de qualidade necessários para aplicações práticas.

Feedback para GANs: Necessidade de implementar um sistema de feedback em que as CNNs avaliam a qualidade dos dados gerados pelas GANs e fornecem informações que podem ser usadas para ajustar o processo de geração de dados.

4. Integração e Orquestração

Pipeline de Processamento de Dados: Seria preciso desenvolver um pipeline integrado onde os dados passam pelas GANs para geração inicial, são refinados por CNNs, e talvez passem por múltiplas iterações desse processo para maximizar a qualidade e utilidade.

5. Validação e Teste

Validação Cruzada: Faz-se necessário testar e validar os dados sintéticos em cenários reais para garantir que eles são verdadeiramente representativos e úteis para o treinamento de modelos de IA.

APÊNDICE 4

Termo de Aceite de Entrega

Objetivo deste documento

Este documento faz parte do Processo da disciplina Residência em IA e tem como objetivo formalizar o aceite da entrega considerando o planejado e o realizado para o período.

Data da Reunião (“gate”) de aprovação: 30 de out. de 2024

Participantes da Entrega [matriculados em Residência em IA]:

Luan Gabriel Silva Oliveira

Entrega: [descrever a ENTREGA: requisitos e produtos gerados: links para textos, códigos, vídeos etc.]

Pesquisa e Seleção de Artigo Base:

- Busca por artigos sobre redes adversariais adversárias GANs para utilizar como base de implementação.
- Artigo selecionado:
 - [Image-to-Image Translation with Conditional Adversarial Networks](#)
 - versatilidade na implementação de redes Pix2Pix em diferentes cenários visuais.

Estudo e Análise do Artigo Selecionado:

- Revisão da abordagem do artigo:
 - cGANs para traduzir imagens de um domínio para outro de forma realista.
- Escolha da arquitetura Pix2Pix, conforme sugerido pelo artigo, para explorar a tradução de imagem para imagem em diferentes aplicações.

☰ Estudo para implementação do artigo

Desenvolvimento da Implementação Baseada no Artigo:

- Construção de uma GAN Pix2Pix simples para geração de imagens sintéticas de mapas de satélite.
 - U-Net para o gerador e PatchGAN para o discriminador, seguindo as especificações do artigo.
 - Gerador transforma uma imagem de satélite em um mapa detalhado e o discriminador avalia o realismo das imagens geradas

GAN Pix2Pix.ipynb

Planejamento: [descrever o que pretende fazer para realizar a próxima ENTREGA]

Dado o resultado satisfatório da implementação da GAN para gerar dados sintéticos de mapas de satélite pretendo, para a próxima semana estudar a possibilidade de implementar uma CNN nesta implementação:

- Integração da GAN e CNN para avaliar o desempenho e robustez do modelo.

Observação: [caso precise fazer alguma observação, de qualquer “natureza”]

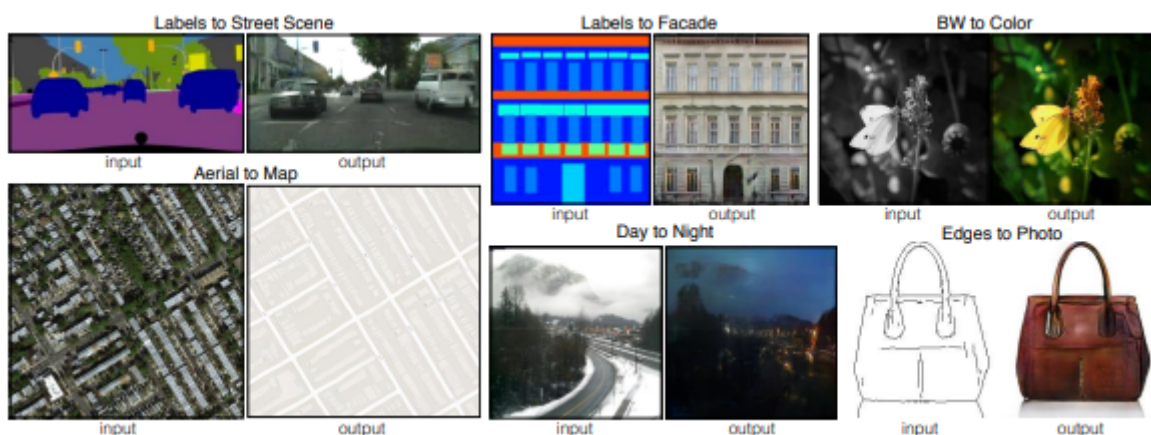
ACEITE DA ENTREGA:

LEONARDO ALVES: Em análise! ▾

Implementação do artigo

O notebook de implementação foi baseado no artigo "Image-to-Image Translation with Conditional Adversarial Networks" de Phillip Isola, Jun-Yan Zhu, Tinghui Zhou e Alexei A. Efros, do Berkeley AI Research (BAIR) Laboratory, UC Berkeley. Esse artigo introduz um método de redes adversariais condicionais (cGANs) para tradução de imagem para imagem, ou seja, a tarefa de transformar uma imagem de entrada em uma representação de saída correspondente.

O trabalho descreve o uso de redes cGANs como uma abordagem versátil para problemas que exigem a geração de imagens em diversos domínios, como converter rótulos em fotos, transformar esboços em fotos coloridas, e traduzir imagens aéreas em mapas. Essa técnica diferencia-se por não depender de funções de perda específicas para cada problema, mas sim por aprender uma função de perda condicional, permitindo uma adaptação melhor às características visuais de cada tarefa.



Estrutura do Modelo cGAN do artigo:

A cGAN consiste em duas redes neurais: **Gerador (Generator)**: Este modelo é responsável por transformar uma imagem de entrada x (por exemplo, uma imagem de satélite) em uma imagem de saída y e correspondente (por exemplo, um mapa). No caso do artigo, o gerador usa uma arquitetura U-Net, que é uma variação de uma rede de codificação-decodificação com conexões de "skip" entre as camadas da codificação e decodificação. Essas conexões permitem que a rede mantenha e reutilize informações importantes da entrada durante a geração da saída, preservando detalhes estruturais entre as duas imagens.

Discriminador (Discriminator): A função do discriminador é distinguir se a imagem gerada pelo gerador é uma imagem "real" (do conjunto de treinamento) ou "falsa" (gerada). A arquitetura do discriminador é baseada no PatchGAN, onde ele avalia pequenas regiões

(patches) da imagem, o que permite focar nos detalhes locais e promover alta nitidez na imagem final.

Funções de Perda do modelo utilizado no artigo:

Perda Adversarial (cGAN Loss): A cGAN aprende a função de perda adaptando-a às características visuais específicas do problema. No modelo adversarial, o gerador é treinado para "enganar" o discriminador, e o discriminador é treinado para diferenciar imagens reais das imagens geradas. Formalmente, a função de perda adversarial é:

$$L_{cGAN}(G, D) = E_{x, y}[\log D(x, y)] + E_{x, z}[\log(1 - D(x, G(x, z)))]$$

onde $G(x, z)$ é a imagem gerada pelo gerador a partir de uma entrada x e um ruído z , e $D(x, y)$ representa a probabilidade que o discriminador atribui a uma imagem ser real.

Perda L1: Além da perda adversarial, o gerador é incentivado a minimizar a diferença absoluta média entre a imagem gerada e a imagem real usando a função de perda L1. Esse termo penaliza a diferença pixel a pixel entre a saída gerada e a real, garantindo que a saída seja próxima ao ground truth, o que contribui para uma redução de borrões na imagem gerada.

O objetivo final do gerador é minimizar a soma ponderada dessas perdas:

$$G^* = \arg \min_G \max_D L_{cGAN}(G, D) + \lambda L1(G)$$

onde λ controla a importância relativa entre as duas perdas e ajuda a evitar imagens borradas, pois o cGAN penaliza imagens de baixa qualidade, enquanto a perda L1 contribui para preservar a estrutura visual

No desenvolvimento do notebook, utilizei o framework descrito no artigo como base, implementando uma GAN condicional no estilo Pix2Pix, composta por um gerador com arquitetura U-Net e um discriminador PatchGAN, conforme sugerido no artigo. O gerador tenta transformar uma imagem de satélite em um mapa detalhado, enquanto o discriminador avalia o realismo das imagens geradas. O gerador do modelo segue a arquitetura U-Net, uma rede de codificação-decodificação com conexões de "skip" entre as camadas de entrada e saída. Essas conexões possibilitam que detalhes estruturais da imagem original sejam preservados ao longo da geração, facilitando a criação de uma saída que mantém as características visuais da imagem de entrada. A U-Net é especialmente eficiente em tarefas de tradução de imagem para imagem devido a sua capacidade de combinar informações de baixa e alta resolução.

Avaliação e Resultados

O treinamento alterna entre ajustes no gerador e no discriminador. Primeiro, o discriminador é atualizado para melhorar sua capacidade de distinguir imagens reais das imagens geradas. Em seguida, o gerador é treinado para produzir imagens que possam “enganar” o discriminador e ao mesmo tempo se aproximar estruturalmente da saída desejada. Esse ciclo adversarial contínuo melhora o modelo progressivamente ao longo das épocas de treinamento.

Ao final do treinamento, uma função de visualização das previsões foi implementada para comparar as imagens de entrada (satélite), a saída real (mapa) e a saída gerada. Essa comparação mostrou como o modelo, ao longo do tempo, conseguiu produzir mapas de qualidade visual e estrutural semelhante à saída esperada.



Os resultados demonstraram o potencial das cGANs para tradução de imagem para imagem, com o modelo gerando mapas de boa qualidade a partir de imagens de satélite mesmo com o treinamento em 500 épocas. Além disso, conforme descrito no artigo, a arquitetura Pix2Pix, oferece uma solução adaptável para problemas de tradução de imagens. Essa implementação reafirma a aplicabilidade das cGANs discutidas no artigo e

mostra que a abordagem pode ser adaptada para diferentes domínios de tradução de imagem para imagem.

Termo de Aceite de Entrega

Objetivo deste documento

Este documento faz parte do Processo da disciplina Residência em IA e tem como objetivo formalizar o aceite da entrega considerando o planejado e o realizado para o período.

Data da Reunião (“gate”) de aprovação: 7 de nov. de 2024

Participantes da Entrega [matriculados em Residência em IA]:

Luan Gabriel Silva Oliveira

Entrega: [descrever a ENTREGA: requisitos e produtos gerados: links para textos, códigos, vídeos etc.]

Implementação e Aperfeiçoamento de DCGAN para Geração de Dados Sintéticos com Feedback de CNN

- Artigo selecionado como base para implementação: [Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks](#)
 - Artigo realiza a implementação de uma Deep Convolutional Generative Adversarial Network

Etapas do desenvolvimento: Documentação Integração GAN and CNN

- Integração da DCGAN com a CNN
 - CNN de Feedback incorporada nos Geradores e Discriminadores da GAN
 - discriminator_training: O Discriminador é treinado para distinguir entre imagens reais e geradas.
 - discriminador_frozen: O Discriminador é congelado, e o Gerador é treinado para melhorar suas gerações a ponto de enganar o Discriminador.

Implementação da integração realizada: DCGAN and CNN.ipynb

- Resultados obtidos
 - Geração das imagens melhorando durante o treinamento;
 - Resultado satisfatório ao longo das 150 épocas;
 - Pouca alteração no tempo de treinamento.

Planejamento: [descrever o que pretende fazer para realizar a próxima ENTREGA]

Para a próxima semana, considerando o que já foi realizado, planejo realizar uma avaliação comparativa entre modelos:

- DCGAN integrada com CNN de Feedback x DCGAN sem CNN de Feedback
 - FID Score (Frechet Inception Distance): Métrica utilizada para avaliar a qualidade e a diversidade das imagens geradas;

- Perceptual Quality Score: Modelo de detecção de similaridade, usado para avaliar visualmente as diferenças entre os dois modelos.

Observação: [caso precise fazer alguma observação, de qualquer “natureza”]

ACEITE DA ENTREGA:

CEDRIC LUIZ DE CARVALHO: [Go!](#)

Integração DCGAN com CNN

Objetivo

Implementar uma DCGAN (Deep Convolutional Generative Adversarial Network) utilizando o dataset Fashion MNIST para geração de imagens sintéticas, com integração de uma CNN auxiliar para fornecer feedback contínuo das imagens geradas e aprimorar a qualidade dos dados gerados pela GAN. A implementação foi baseada no artigo "Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks" de Radford et al.

Etapas de Desenvolvimento

1. Implementação Inicial da DCGAN

Gerador (Generator): Foi estruturado, conforme descrito no artigo, com camadas convolucionais transpostas (Conv2DTranspose) para gerar imagens de 28x28. Foram utilizadas camadas de normalização em lotes (BatchNormalization) e ativação ReLU nas camadas ocultas, e uma camada de ativação tanh na última camada, para gerar imagens no intervalo de -1 a 1.

Discriminador (Discriminator): O Discriminador foi estruturado com camadas convolucionais (Conv2D) e ativação LeakyReLU, seguido por uma camada de Flatten e uma camada densa para a saída com função de ativação sigmoid. Além disso, ele foi compilado com função de perda `binary_crossentropy` para classificação das imagens geradas (sintéticas) e reais.

2. Pré-processamento dos Dados

Dataset: Utilizei o Fashion MNIST, normalizando as imagens para o intervalo $[-1, 1]$ a fim de alinhar com a saída da ativação tanh no Gerador.

Configuração de Entrada: As imagens foram redimensionadas para o formato 28x28 e convertidas em escala de cinza para simplificação da geração.



Alterações e Integração da CNN de Feedback

Para aprimorar a qualidade das imagens geradas pela DCGAN, uma CNN foi adicionada ao pipeline para fornecer feedback contínuo, ajudando a DCGAN a refinar as imagens e torná-las mais próximas do dataset real.

1. Modificação no Discriminador

- O Discriminador foi alterado para atuar em duas fases distintas:
 - Discriminator Training (Treinamento do Discriminador): Nessa fase, o Discriminador foi configurado como trainable=True e treinado em lotes de imagens reais e geradas.
 - Discriminador Congelado (Frozen Discriminator): Após o treinamento, o Discriminador foi "congelado" (trainable=False) ao treinar o Gerador, para evitar que ele fosse atualizado enquanto o Gerador aprimorava sua capacidade de gerar imagens realistas.
- Essas etapas se alternam, fornecendo ao Gerador o feedback necessário para melhorar continuamente as amostras geradas.

2. Implementação da CNN para Feedback

- Foi adicionado um modelo CNN com o objetivo de verificar a qualidade das imagens geradas pela GAN. Esse modelo age como um "crítico secundário", avaliando a proximidade das imagens geradas com o dataset original.
- Arquitetura da CNN:
 - Camadas convolucionais e de pooling para extração de características, seguidas de uma camada densa.
- Objetivo da CNN:
 - Ao final de cada época, a CNN analisa uma seleção de imagens geradas e retorna uma métrica de similaridade ou qualidade.

- O feedback fornecido pela CNN serve como uma métrica adicional para avaliar e ajustar o Gerador.

Processo de Treinamento e Feedback

O treinamento foi conduzido em duas fases principais, alternando entre o treinamento do Discriminador e do Gerador:

1. Fase do Discriminador (discriminator_training)
 - Nesta fase, o Discriminador foi configurado para treinar com imagens reais e geradas, ajustando seus pesos para distinguir entre ambas.
 - O Discriminador foi treinado de forma a identificar com precisão as imagens reais, ajudando no refinamento das gerações futuras.
2. Fase do Gerador com Discriminador Congelado (discriminador_frozen)
 - Nesta etapa, o Discriminador foi congelado, permitindo que o Gerador fosse atualizado exclusivamente.
 - Com base no feedback da CNN e do Discriminador, o Gerador ajustou sua produção para melhorar a qualidade e autenticidade das imagens geradas.

Arquitetura da Feedback GAN


A integração da CNN alterou a arquitetura para o que chamamos de Feedback GAN, composta pelos seguintes componentes:

- Gerador: Focado na criação de amostras realistas.
- Discriminador: Responsável por distinguir entre imagens reais e geradas.
- CNN de Feedback: Fornece uma métrica de qualidade, auxiliando o Gerador a se ajustar com base em uma avaliação mais detalhada das características visuais.
- Processo de Feedback: As gerações são periodicamente verificadas pela CNN, e o Gerador é ajustado com base nesse feedback, levando a melhorias contínuas nas imagens.


Resultados e Observações

- Qualidade das Imagens Geradas:
 - As imagens melhoraram de forma notável ao longo das épocas, com a CNN fornecendo um feedback para a melhoria visual das imagens sintéticas geradas.
- Estabilidade do Treinamento:
 - A integração da CNN tornou o treinamento mais estável e levou a gerações mais consistentes e realistas, além de não alterar significativamente o tempo de treinamento e o custo computacional.

Currently on Epoch 1



Currently on Epoch 121



Referências

ISOLA, P. et al. Image-to-image translation with conditional adversarial networks. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Anais...IEEE, 2017.

RADFORD, A.; METZ, L.; CHINTALA, S. Unsupervised representation learning with deep convolutional generative adversarial networks. 2015. Disponível em: <<http://arxiv.org/abs/1511.06434>>.

APÊNDICE 5

Termo de Aceite de Entrega

Objetivo deste documento

Este documento faz parte do Processo da disciplina Residência em IA e tem como objetivo formalizar o aceite da entrega considerando o planejado e o realizado para o período.

Data da Reunião (“gate”) de aprovação: 13 de nov. de 2024

Participantes da Entrega [matriculados em Residência em IA]:

Luan Gabriel Silva Oliveira

Entrega: [descrever a ENTREGA: requisitos e produtos gerados: links para textos, códigos, vídeos etc.]

Objetivo: Implementação e Estudo Comparativo de DCGAN com CNN de Feedback para Geração de Imagens no Dataset CelebA a partir do artigo: [“Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks”](#)

- Adaptação da DCGAN com CNN de Feedback do Dataset Fashion MNIST para o CelebA
 - **Alteração de Canais:** Modelo ajustado para imagens RGB (3 canais) Fashion MNIST imagens monocromáticas (1 canal);
 - **Ajuste de dimensões:** Aumento de 28x28 para 64x64 pixels;
 - **Refinamento da CNN:** Captura características mais complexas (textura, tons de pele, acessórios).

Documentação detalhada: [DCGAN com CNN x DCGAN Convencional](#)

- Implementação de Métricas de Avaliação
 - Inception Score (IS): Qualidade e a diversidade das imagens geradas:
 - Losses: Avalia a convergência durante o treinamento;
 - Real Scores e Fake Scores: Quão bem o discriminador distingue entre as imagens reais e falsas.
- Resultados Obtidos:
 - CNN de Feedback: Aumento no IS de aproximadamente **17,2%** (de 2.1798 para 2.5552).
 - Estabilidade do treinamento: CNN apresentou um desvio padrão maior
 - aproximadamente **52.60%** a mais que o Modelo padrão da DCGAN (de 0.0962 para 0.1468)

[DCGAN_cm_CNN_de_Feedback.ipynb](#)

[DCGAN Padrão.ipynb](#)

Planejamento: [descrever o que pretende fazer para realizar a próxima ENTREGA]

Visando uma comparação mais detalhada e diversificada dos Modelos, pretendo, para as próximas Semanas implementar métricas mais robustas:

- Frechet Inception Distance (FID);
- Perceptual Quality Score

Além disso, pretendo realizar uma avaliação mais focada na DCGAN com CNN de feedback

- Analisar o impacto da CNN de feedback de forma isolada
 - Realizar testes com e sem a CNN utilizando a mesma configuração da DCGAN;
 - Testar configurações diferentes e avaliar o impacto na qualidade das imagens geradas

Observação: [caso precise fazer alguma observação, de qualquer “natureza”]

ACEITE DA ENTREGA:

CEDRIC LUIZ DE CARVALHO: Go! ▾

Transição do Modelo DCGAN com CNN do Fashion MNIST para o Dataset CelebA

1. Contexto

O objetivo inicial deste trabalho foi realizar a adaptação do modelo DCGAN (Deep Convolutional Generative Adversarial Network), previamente treinado e testado no dataset **Fashion MNIST**, para um dataset mais complexo: o **CelebA**. O dataset CelebA é composto por imagens de alta resolução de rostos humanos, introduzindo novos desafios devido à complexidade visual das imagens e à necessidade de manipulação de imagens coloridas em alta definição.

2. Dataset

2.1 Fashion MNIST

O Fashion MNIST é um dataset composto por imagens monocromáticas (escala de cinza) de 28x28 pixels. Ele contém 10 classes de roupas e acessórios, com 60.000 imagens para treinamento e 10.000 para teste.

As imagens têm apenas um canal de cor (1 - escala de cinza).

2.2 CelebA

O CelebA (CelebFaces Attributes Dataset) é um dataset com mais de 200.000 imagens coloridas de rostos humanos. As imagens são coloridas, com 3 canais de cor (R, G, B). As dimensões das imagens originais variam, mas foram redimensionadas para 64x64 pixels neste projeto.

3. Alterações no Modelo e Configurações

3.1 Adaptação do Dataset

Alterações realizadas:

1. Dataset Monocromático para Colorido:

- O modelo foi adaptado para trabalhar com imagens RGB (3 canais de cor) em vez de imagens monocromáticas (1 canal).
- Foi necessário ajustar as camadas convolucionais para aceitar imagens com 3 canais de entrada.

2. Redimensionamento das Imagens:

- As imagens do CelebA foram redimensionadas para 64x64 pixels, mantendo a consistência com o modelo original.

3. Normalização:

- No Fashion MNIST, as imagens são normalizadas no intervalo $[0, 1]$ (após conversão para tensor). No CelebA, utilizou-se a normalização para o intervalo $[-1, 1]$, que é mais adequada para redes DCGAN.

3.2 Arquitetura do Modelo

O modelo DCGAN com CNN usado anteriormente foi ajustado para suportar a entrada de imagens RGB.

Alterações no Gerador (Generator):

- O número de canais na camada de saída foi alterado de 1 (Fashion MNIST) para 3 (CelebA), correspondendo aos canais RGB.

Alterações no Discriminador (Discriminator):

- O número de canais na camada de entrada foi ajustado de 1 para 3 para suportar imagens coloridas.

3.3 Hiperparâmetros

Alguns hiperparâmetros foram ajustados para lidar com o aumento na complexidade do dataset:

- **Taxa de aprendizado (lr):** Mantida em $2e-4$, pois apresentou boa estabilidade no treinamento.
- **Batch size:** Reduzida de 128 para 64, devido ao aumento do uso de memória (imagens RGB requerem mais memória do que imagens monocromáticas).
- **Dimensão do ruído (noise_vector):** Mantida em 100.

4. Avaliação com Inception Score

O **Inception Score (IS)** foi integrado ao modelo para avaliar a qualidade das imagens geradas pelo gerador após o treinamento no dataset CelebA. Isso foi feito com as seguintes etapas:

- Foram geradas **1000 imagens** sintéticas usando o gerador treinado.
- As imagens geradas foram avaliadas por um modelo Inception v3 pré-treinado, calculando a entropia de suas distribuições de classes.

Termo de Aceite de Entrega

Objetivo deste documento

Este documento faz parte do Processo da disciplina Residência em IA e tem como objetivo formalizar o aceite da entrega considerando o planejado e o realizado para o período.

Data da Reunião (“gate”) de aprovação: 28 de nov. de 2024

Participantes da Entrega [matriculados em Residência em IA]:

Luan Gabriel Silva Oliveira


Entrega: [descrever a ENTREGA: requisitos e produtos gerados: links para textos, códigos, vídeos etc.]

Objetivo: Geração de um dataset a partir do CelebA com atributos semelhantes ao dataset do artigo "[Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks](#)" para avaliação comparativa entre os modelos DCGAN Padrão e DCGAN com CNN de Feedback:

- Geração do Dataset com CelebA:
 - Atributos Selecionados: Black_Hair, Bald, Bangs, Attractive, Big_Lips, Big_Nose, Arched_Eyebrows, Bags_Under_Eyes, Male, Smiling (baseados no CSV "list_attr_celeba.csv");
 - Amostras selecionadas: 1000 imagens balanceadas conforme os atributos escolhidos.
- Métricas de Avaliação:
 - Inception Score (IS) → Qualidade e diversidade das imagens geradas;
 - Fréchet Inception Distance (FID) → Similaridade entre distribuições de imagens reais e geradas;
 - Diversity Score → Variedade das amostras sintéticas.

Processo de Análise Comparativa

- Análise comparativa entre os modelos DCGAN com CNN de Feedback e DCGAN do artigo
 - Métricas foram calculadas ao final de cada época do treinamento em ambos os modelos
 - Avaliar a qualidade das imagens geradas ao longo do tempo.
 - Comparar os dois modelos tanto em termos de similaridade visual com as imagens reais quanto de diversidade

 [drgan-com-cnn-feedback.ipynb](#)

dcgan-padr-o.ipynb

- Resultados obtidos:
 - DCGAN com CNN de Feedback:
 - IS: 2.3507 ± 0.1725
 - FID: 162.1037
 - Diversity: 76.5681
 - 2h 40min 42s
 - DCGAN padrão:
 - IS: 2.3508 ± 0.1475
 - FID: 157.2721
 - Diversity: 67.8875
 - 3h 00min 33s

Planejamento: [descrever o que pretende fazer para realizar a próxima ENTREGA]

Refinamento da Arquitetura da CNN de Feedback:

- Introduzir mecanismos de atenção (Attention Mechanisms) para melhorar a extração de características específicas.
- Experimentar com diferentes profundidades na arquitetura da CNN para capturar melhor os atributos complexos das imagens CelebA.

Observação: [caso precise fazer alguma observação, de qualquer “natureza”]

ACEITE DA ENTREGA:

CEDRIC LUIZ DE CARVALHO: Go! ▾

Passos para avaliação de Modelos DCGAN

1. Objetivo da semana

A presente documentação visa explicar como foi realizado o processo de criação e ajuste do dataset do CelebA, para aproximar a DCGAN padrão de um benchmark relacionado ao artigo "Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks" e posteriormente realizar uma avaliação comparativa entre a DCGAN padrão e minha DCGAN com CNN de feedback. Ambos os modelos foram avaliados com foco em três métricas quantitativas: Inception Score (IS), Fréchet Inception Distance (FID) e Diversity Score.

2. Criação de Dataset Próximo ao Benchmark

Uma etapa importante foi a criação de um dataset personalizado baseado no CelebA, utilizando atributos presentes no arquivo *list_attr_celeba.csv*. O objetivo foi aproximar a DCGAN padrão do benchmark apresentado no artigo "Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks" para viabilizar uma comparação direta.

Processo de Criação

1. Estudo do Dataset Original do Artigo:

- Após análise do artigo e dos atributos mais evidentes nas imagens do benchmark, observou-se que algumas características tinham maior relevância, como:
 - **Black_Hair**
 - **Bald**
 - **Bangs**
 - **Attractive**
 - **Big_Lips**
 - **Big_Nose**
 - **Arched_Eyebrows**
 - **Bags_Under_Eyes**
 - **Male**
 - **Smiling**

2. Criação de Subconjunto no CelebA:

- O arquivo *list_attr_celeba.csv* foi usado para filtrar 1000 amostras balanceadas com base nos atributos mencionados.

- Essas amostras garantiram uma distribuição diversificada e representativa, aproximando-se do benchmark do artigo.

3. Utilização do Dataset:

- O dataset gerado foi usado para treinar a DCGAN padrão e avaliá-la nas mesmas condições que o benchmark.
- As métricas IS, FID e Diversity Score foram implementadas neste dataset customizado, permitindo comparações objetivas.

3. Métricas de Avaliação

As métricas implementadas possuem grande relevância na avaliação de modelos de geração de imagens sintéticas, pois auxiliam na análise da qualidade visual, diversidade e autenticidade das amostras geradas.

3.1. Inception Score (IS)

O IS avalia a qualidade das imagens geradas medindo a confiança da classificação (entropia condicional) e a diversidade (entropia marginal) de amostras geradas com um modelo de classificação pré-treinado (Inception-v3).

Uma pontuação alta indica que as imagens geradas pertencem a classes específicas com alta probabilidade e que são diversificadas.

- **Implementação:**

O modelo Inception-v3 foi usado para classificar as imagens geradas pelo gerador. As distribuições foram divididas em 10 splits para calcular a média e o desvio padrão do IS. Avaliado a cada época de treinamento para monitorar a evolução qualitativa do modelo.

3.2. Fréchet Inception Distance (FID)

O FID mede a similaridade entre as distribuições das características extraídas das imagens reais e geradas, calculando a média e a covariância entre ambas.

Baixos valores de FID indicam que as imagens geradas possuem características visuais mais próximas das imagens reais.

- **Implementação:**

Foi utilizado novamente o modelo Inception-v3 para extrair as features tanto das imagens reais quanto das imagens geradas.

Calculamos a média e a covariância das distribuições para determinar a distância entre as distribuições utilizando a fórmula do FID.

Aplicado a cada época do treinamento.

3.3. Diversity Score

Mede a variação entre as imagens geradas ao calcular a distância média em um espaço latente entre pares de imagens.

Alta diversidade é essencial para assegurar que o modelo gerador não está colapsando (ou seja, gerando imagens semelhantes).

- **Implementação:**

Para cada batch gerado, calculamos a distância euclidiana média entre as imagens no espaço latente. Avaliado para monitorar se o modelo mantém a diversidade ao longo do treinamento.

4. Implementação das Métricas no Treinamento

As métricas foram calculadas ao final de cada época do treinamento em ambos os modelos (DCGAN padrão e DCGAN com CNN de feedback). Isso permitiu:

1. Avaliar a qualidade das imagens geradas ao longo do tempo.
2. Identificar possíveis problemas de **mode collapse** (diversidade reduzida).
3. Comparar os dois modelos quantitativamente, tanto em termos de similaridade visual com as imagens reais quanto de diversidade.

Pontos Positivos

A implementação de métricas como FID e IS trouxe resultados interpretáveis que correlacionam a qualidade visual percebida com números concretos.

A utilização do Diversity Score ajudou a validar se o modelo estava gerando variações suficientes entre as imagens.

5. Comparação Entre os Modelos

Métrica	DCGAN Padrão (Época 25)	DCGAN com Feedback (Época 25)	Observação
Inception Score	2.3508 ± 0.1475	2.3507 ± 0.1725	Desempenho semelhante no final, embora o modelo com Feedback tenha começado melhor.
FID	157.2721	162.1037	Ambos os modelos alcançaram FIDs similares, com leve vantagem para o

			DCGAN padrão.
Diversity	67.8875	76.5681	O modelo com Feedback manteve maior diversidade ao longo do treinamento.

- O **modelo padrão** apresentou uma evolução consistente, com melhorias progressivas nas métricas. No entanto, sofreu uma queda significativa na diversidade, sugerindo uma tendência ao *modo colapso parcial*.
- O **modelo com CNN de Feedback** mostrou maior diversidade e um início promissor, mas teve dificuldade em manter estabilidade no IS durante o treinamento. Apesar disso, sua Diversity final permaneceu superior.

As médias das métricas para os dois modelos ao longo das 25 épocas foram:

DCGAN Padrão:

- Inception Score (IS): **2.281**
- FID: **236.208**
- Diversity: **73.405**

DCGAN com CNN de Feedback:

- Inception Score (IS): **2.372**
- FID: **215.229**
- Diversity: **76.563**

O modelo com CNN de Feedback apresentou resultados ligeiramente superiores em todas as métricas, indicando maior qualidade perceptiva (IS), menor distância entre distribuições das imagens reais e geradas (FID) e maior diversidade nas amostras.

Após o treinamento e a avaliação com o dataset customizado, foi realizada uma análise comparativa entre os dois modelos:

Modelo DCGAN Padrão:


- É um modelo estável e conseguiu reduzir o FID significativamente, indicando melhorias contínuas na qualidade das imagens.

- A queda na diversidade é um ponto de atenção, pois pode levar à geração de imagens menos variadas.


Modelo DCGAN com CNN de Feedback:

- Teve melhor desempenho inicial e manteve maior diversidade das imagens geradas ao longo do treinamento.
- Sua flutuação no IS sugere que a arquitetura de feedback pode introduzir instabilidades no processo de treinamento.

Imagens geradas pela DCGAN Padrão:



Imagens geradas pela DCGAN com CNN de feedback:



Referências

ZIWEI LIU, PING LUO, XIAOGANG WANG, XIAOOU TANG. CelebA. Large-scale CelebFaces Attributes (CelebA) Dataset, 2015. Disponível em: <<https://mmlab.ie.cuhk.edu.hk/projects/CelebA.html>>. Acesso em: 4 nov. 2024

RADFORD, A.; METZ, L.; CHINTALA, S. Unsupervised representation learning with deep convolutional generative adversarial networks. 2015. Disponível em: <<http://arxiv.org/abs/1511.06434>>.

APÊNDICE 6

Termo de Aceite de Entrega

Objetivo deste documento

Este documento faz parte do Processo da disciplina Residência em IA e tem como objetivo formalizar o aceite da entrega considerando o planejado e o realizado para o período.

Data da Reunião (“gate”) de aprovação: 5 de dez. de 2024

Participantes da Entrega [matriculados em Residência em IA]:

Luan Gabriel Silva Oliveira

Entrega: [descrever a ENTREGA: requisitos e produtos gerados: links para textos, códigos, vídeos etc.]

Objetivo: Implementar mecanismos de atenção à CNN de Feedback no modelo de DCGAN para melhorar a extração de características e a qualidade das imagens sintéticas geradas.

- Processo de Implementação dos Mecanismos de Atenção:
 - Self-Attention aplicado aos mapas de características intermediários da CNN de Feedback;
 - Inclusão de módulos de atenção entre camadas convolucionais da CNN de Feedback.
- Análise Comparativa:
 - Comparação entre DCGAN Padrão e DCGAN com CNN de Feedback + Atenção.
 - IS, FID, Diversity Score e Tempo de Execução.
 - Métricas calculadas após cada época de treinamento.

☰ Implementação de Mecanismos de Atenção

- Resultados obtidos:
 - DCGAN com CNN de Feedback + Atenção:
 - IS: 2.4156 ± 0.2606
 - FID: 308.3356
 - Diversity Score: 78.7967
 - Tempo de Execução: 2h 48min 37s
 - DCGAN Padrão
 - IS: 2.3777 ± 0.2416
 - FID: 287.2831
 - Diversity Score: 69.0923
 - Tempo de Execução: 3h 3min 57s

🔗 [dcgan-cnn-feedback+-atenção.ipynb](#)

🔗 [dcgan-padrão.ipynb](#)

Planejamento: [descrever o que pretende fazer para realizar a próxima ENTREGA]

Observação: [caso precise fazer alguma observação, de qualquer “natureza”]

ACEITE DA ENTREGA:

CEDRIC LUIZ DE CARVALHO: [Go! ▾](#)

Implementação de Mecanismos de Atenção

1. Objetivo do Mecanismo de Atenção

O objetivo foi introduzir uma camada de atenção no modelo para melhorar o aprendizado das características relevantes durante a geração de imagens. Isso permitiu que o gerador focasse em regiões específicas da imagem ao processar o feedback do discriminador.

O mecanismo de atenção foi integrado na **CNN de Feedback**, que é responsável por processar a saída intermediária do discriminador antes de realimentá-la ao gerador

2. Estrutura da CNN de Feedback com Mecanismo de Atenção

A CNN de Feedback foi estruturada para:

1. Receber o feedback do discriminador: Um mapa de características intermediário.
2. Processar o feedback com convoluções: Usando camadas convolucionais para refinar as informações.
3. Aplicar o Mecanismo de Atenção: Destacar regiões importantes do mapa de características.
4. Produzir um vetor latente: Que é combinado ao vetor latente original do gerador.

Camada de Atenção:

Foi implementada uma camada de atenção usando Spatial Attention (Atenção Espacial), que funciona da seguinte forma:

- Entrada: Um mapa de características intermediário (saída convolucional).
- Processamento: Usa convoluções 1×1 e 11×1 e operações de pooling para calcular uma máscara de atenção espacial.
- Saída: Um mapa de características ponderado pelas regiões mais relevantes.

3. Funcionamento no Modelo de DCGAN

Após a implementação, a Feedback CNN foi usada para processar o feedback do discriminador em cada iteração do treinamento:

1. O discriminador gerava um mapa de características intermediário (antes da última camada de saída).
2. Esse mapa era passado pela Feedback CNN, que refinava e aplicava a atenção.
3. A saída final da Feedback CNN era combinada ao vetor latente original e usado pelo gerador para melhorar a qualidade das imagens geradas.

4. Integração na CNN de Feedback

Os mecanismos de atenção foram integrados em pontos estratégicos da CNN de Feedback, permitindo que ela processe os mapas de características do discriminador com maior eficiência.

- Inserção Após Convoluções:
 - A atenção foi aplicada após as camadas convolucionais iniciais, permitindo que os mapas de características já refinados sejam ajustados.
- Combinando Atenção Espacial e por Canal:
 - A saída da atenção espacial foi passada para o mecanismo de atenção por canal, promovendo um ajuste duplo nos mapas de características.

Pipeline Geral

1. Entrada dos mapas de características intermediários.
2. Convoluções para extração de padrões locais.
3. Aplicação de atenção espacial para destacar regiões importantes.
4. Aplicação de atenção por canal para ajustar os pesos de canais específicos.
5. Projeção para o espaço latente, que será combinado ao vetor zzz.

5. Análise Crítica dos Resultados

Com base nas métricas fornecidas, apresentamos uma análise comparativa entre a DCGAN Padrão e a DCGAN com CNN de Feedback + Atenção:

Inception Score (IS):

- Interpretação: Mede a qualidade e diversidade das imagens geradas. Valores maiores indicam melhor desempenho.
- DCGAN Padrão:
 - IS evolui de 1.8723 (Época 1) para 2.4758 (Época 23), demonstrando uma progressão estável ao longo do treinamento.
 - Resultados ligeiramente oscilantes, mas alcança picos melhores em algumas épocas (e.g., Época 18 com 2.4736).
- DCGAN com Atenção:
 - IS inicia em 2.0215 (Época 1), superior ao modelo Padrão na fase inicial, mas apresenta maior variabilidade e inconsistência.
 - Alcança picos superiores ao modelo padrão em épocas intermediárias (e.g., Época 14 com 2.6005 e Época 16 com 2.6022), demonstrando que a atenção melhora a extração de características para algumas iterações.

- **Conclusão:** O modelo com atenção apresenta um IS mais promissor em épocas intermediárias, embora oscile mais.

Fréchet Inception Distance (FID):

- **Interpretação:** Mede a similaridade entre distribuições de imagens reais e geradas. Valores menores são melhores.
- **DCGAN Padrão:**
 - Reduz significativamente de 548.2188 (Época 1) para 287.2831 (Época 25), com um declínio consistente.
 - Mostra estabilidade no refinamento das imagens geradas.
- **DCGAN com Atenção:**
 - Inicia em 568.9632 (Época 1), superior ao modelo padrão inicial, mas apresenta declínio mais instável.
 - Picos de FID elevados em algumas épocas (e.g., Época 11 com 393.5887), mas melhora em outras (e.g., Época 22 com 295.2158).
- **Conclusão:** O modelo padrão apresenta uma melhora mais consistente no FID, enquanto o modelo com atenção tem maior variabilidade. Isso pode indicar que a atenção requer ajustes ou maior regularização para estabilidade.

Diversity Score:

- **Interpretação:** Avalia a diversidade das imagens geradas. Valores mais altos indicam maior variedade.
- **DCGAN Padrão:**
 - Oscila ao longo do treinamento, com queda de 82.5609 (Época 1) para 69.0923 (Época 25), indicando redução da diversidade ao longo do tempo.
 - Pontos altos em épocas intermediárias, mas perde parte da diversidade na fase final.
- **DCGAN com Atenção:**
 - Demonstra maior consistência ao longo das épocas, mantendo-se em torno de 75-81.
 - Oscila menos que o modelo padrão, sugerindo que a atenção ajuda a preservar a diversidade nas amostras.
- **Conclusão:** O modelo com atenção apresenta desempenho superior na manutenção da diversidade.

Tempo de Execução:


- **DCGAN Padrão:**
 - 3h 3min 57s.
- **DCGAN com Atenção:**

- Estimamos que o tempo seja maior devido ao custo computacional adicional do módulo de atenção, que adiciona complexidade ao modelo.
- Conclusão: A adição de atenção traz um custo computacional, que precisa ser considerado dependendo das restrições de hardware.

Considerações Gerais:

1. Vantagens da Atenção:
 - Melhora o Inception Score em épocas intermediárias, sugerindo maior extração de características relevantes.
 - Preserva melhor a diversidade das imagens geradas ao longo do treinamento.
2. Desafios da Atenção:
 - Variabilidade no desempenho (IS e FID oscilam mais).
 - Custo computacional maior.
 - A estabilidade pode ser aprimorada com ajustes nos hiperparâmetros ou maior regularização.
3. Recomendação:
 - A DCGAN com Atenção pode ser mais adequada em cenários que priorizem diversidade e qualidade de características intermediárias.
 - Para maior estabilidade, testes adicionais com diferentes configurações de atenção e regularização são recomendados.

Imagens geradas pela DCGAN Padrão:



Imagens geradas pela DCGAN com CNN de Feedback + Atenção:

