

Fingerprints Synthesis Using Generative Adversarial Neural Network: Minutiae Structure Analysis

Síntese de Impressões Digitais Usando Rede Neural Generativa Adversarial: Análise de Estrutura de Minúcias

Paulo Cassiano¹, Raoni Florentino da Silva Teixeira¹, Gracyelli Santos Souza Guarienti¹, Joyce Marins¹, Luiz Vinicius Souza Silva¹, Talles Emanuel Coelho Silva¹

¹Departamento de Computação e Automação - Faculdade de Engenharia – Universidade Federal de Mato Grosso (UFMT)

Caixa Postal 78060-900 – Cuiabá – MT – Brasil

paulo.phcm98@gmail.com, raoni.teixeira@ufmt.br,
gracyeli.guarienti@ufmt.br, Joyce.marins@ufmt.br,
luizvini10@hotmail.com, tallescoelho.e@gmail.com

Abstract. *The growing use of fingerprints drives the emergence of studies to enhance the technology, demanding higher quality fingerprint images to ensure good results. Due to the sensitivity of LGPD in Brazil since 2018, sharing fingerprint data is hesitant. In this context, this study creates realistic synthetic fingerprints using the StyleGAN-ADA neural network. The results are evaluated using the Earth mover's distance (EMD) metric to compare 2D distributions, and the Minutiae Histograms (MHs) method to map minutiae distributions. This approach succeeds with the FVC database, generating images that reflect realistic minutiae distributions according to the employed metrics.*

Keywords: *fingerprints. neural network. minutiae structure*

Resumo. *O uso crescente das impressões digitais impulsiona estudos para aprimorar a tecnologia, exigindo imagens de impressão digital de melhor qualidade para garantir bons resultados. Devido à sensibilidade da LGPD no Brasil desde 2018, compartilhar dados de impressões digitais é relutante. Nesse contexto, este estudo cria impressões digitais sintéticas realistas com a rede neural StyleGAN-ADA. Os resultados são avaliados usando a métrica Earth mover's distance (EMD) para comparar distribuições 2D e o método Minutiae Histograms (MHs) para mapear distribuições de minúcias. Essa abordagem obtém êxito com a base de dados FVC, gerando imagens que refletem distribuições realistas de minúcias conforme as métricas empregadas.*

Palavras chave: *impressões digitais. rede neural. estrutura de minúcias*

1. Introdução

O uso das impressões digitais como forma de identificação é comum em tecnologias atuais, oferecendo rapidez e segurança. No entanto, a escassez de bases de dados de impressões de alta qualidade dificulta a pesquisa nessa área. O receio de compartilhar dados sensíveis levou ao uso de sintetizadores para gerar dados sem comprometer a privacidade.

Alguns sintetizadores, baseados em modelos matemáticos e aleatórios, produzem imagens incorretas devido à falta de compreensão dos aspectos complexos. Para superar isso, propõe-se o uso de um modelo generativo adversarial (GAN) para sintetizar imagens realistas de impressões digitais, seguindo a relação entre síntese e reconstrução. Isso será alcançado aplicando os princípios e algoritmos desenvolvidos por Karras et al. (2020) e treinando uma rede neural com base de dados reduzida.

O objetivo é demonstrar que essa abordagem pode resultar em imagens realistas que capturam a complexa estrutura das minúcias presentes nas impressões digitais reais. Essa abordagem oferece contribuições significativas à comunidade científica, permitindo que outras áreas explorem seus benefícios além das impressões digitais. O processo GAN envolve um gerador e um discriminador treinados para criar e distinguir entre amostras reais e sintéticas. O gerador usa uma variável latente para criar amostras falsas, enquanto o discriminador as separa entre reais e falsas.

2. Materiais e Métodos

O uso crescente das biometrias, como impressões digitais, é de grande valia em diversas áreas, mas para melhorar sua eficácia demanda-se um grande volume de dados, o que pode ser problemático devido a regulamentações como a LGPD no Brasil. Essa lei classifica dados biométricos como sensíveis e impõe restrições rigorosas na coleta e uso, mesmo quando são anonimizados, devido à preocupação com a privacidade.

Para superar limitações na qualidade de bases de dados, propõe-se o uso de Redes Neurais Generativas Adversárias (GANs) com aumento de dados adaptativo (ADA) para gerar imagens sintéticas de impressões digitais. Esses dados gerados por IA resolvem questões legais e de privacidade, revelando que essa abordagem gera imagens de alta qualidade em conformidade com a LGPD, auxiliando as pesquisas em biometria.

Para desenvolver o algoritmo, foi seguida uma sequência de passos visando bons resultados. A rede neural do tipo GAN foi escolhida devido às suas capacidades de aprender características difíceis de serem implementadas matematicamente e de sintetizar imagens com base em um treinamento que necessita de dados mínimos.

Para facilitar o aprendizado da rede neural, é importante possuir um conjunto de dados de alta qualidade contendo as características desejadas. Este estudo utilizará dados biométricos da Fingerprint Verification Competition (FVC), uma competição internacional para algoritmos de verificação de impressão digital realizada em 2000, 2002, 2004 e 2006, cujos dados e resultados estão acessíveis em um repositório público.

As quatro edições do FVC possuem quatro conjuntos de dados: DB1, DB2, DB3 e DB4. Os três primeiros contêm imagens reais de diferentes sensores para garantir diversidade, enquanto o último inclui imagens sintéticas geradas pelo sintetizador SFinGe. Para treinamento, os dados foram reorganizados em duas categorias: reais e sintéticas, com apenas as imagens reais sendo usadas na etapa de treinamento da rede.

A rede utilizada exige imagens quadradas padronizadas. Devido à variação na base de dados, as menores foram ajustadas com bordas baseadas na maior dimensão (512 pixels), resultando em um conjunto com todas as imagens no formato 512 x 512.

No contexto das redes neurais, a obtenção de resultados sólidos geralmente demanda uma ampla e rica coleção de dados. Entretanto, este estudo concentra-se na habilidade de criar

impressões digitais sintéticas altamente realistas usando redes neurais, mesmo com poucos dados de treinamento.

A abordagem se baseia na GAN denominada StyleGAN2-ADA, proposta pelos autores Karras et al. (2020). Essa versão, desenvolvida pela NVIDIA, utiliza um mecanismo de aumento de discriminador adaptativo (ADA) para estabilizar o treinamento com dados limitados. A pesquisa destaca o sucesso da NVIDIA na geração de várias imagens por meio de algoritmos GAN, escolhidos devido à sua capacidade de identificar estruturas características do objeto principal, o que é crucial para reproduzir a complexidade das impressões digitais.

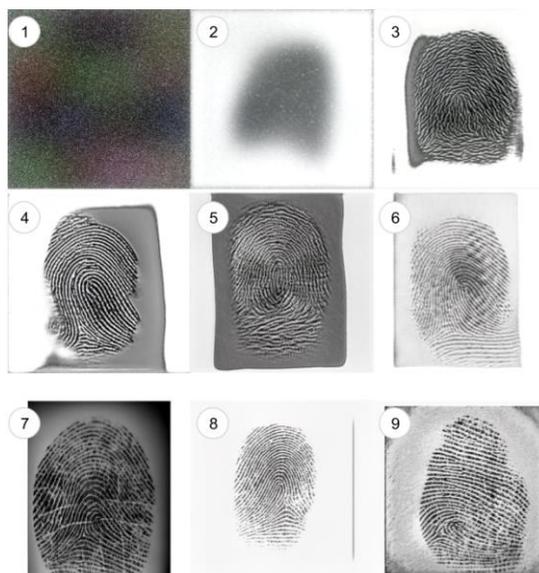


Figura 1. Amostras de etapas do treinamento da StyleGan2-ADA. 1 - 6 Representam resultados sequenciais respectivos à algumas pickle's do treinamento. 7 - 9 São exemplos distintos de imagens geradas com o modelo final treinado. Fonte: Autor.

O processo de treinamento da rede neural teve início com a utilização de 11520 imagens ajustadas para o treinamento, e a técnica "augpipe" foi configurada para permitir várias ampliações, como blit, geom, color, filter, noise e cutout, para otimizar os resultados. A evolução do treinamento é ilustrada na Figura 1, começando com um ruído (1) e progredindo para uma delimitação geral das impressões (2). A partir de (3), surgem cristas e vales, mas sem padrões claros de continuidade. (4) mostra um padrão excessivamente contínuo e não esperado. As imagens (5) e (6) mostram minúcias mais definidas, semelhantes a imagens reais. As imagens (7-9) são geradas pelo modelo e exibem detalhes mais orgânicos, sendo consideradas a versão final do sintetizador GAN.

Foi usado o Verifinger da neurotechnology, mais especificamente o código LatentFingerprintSampleCS para extrair os templates das impressões contendo suas minúcias. Esses templates são basicamente a posição e o ângulo das minúcias de uma impressão digital.

3. Resultados

Após treinar o modelo sintetizador, foram extraídos templates com as minúcias das imagens reais e fake da base FVC. Ademais, sintetizamos e extraímos templates de cerca de 99 mil imagens do gerador GAN para garantir uma análise mais precisa. Para validar

sua fidelidade quanto à estrutura, comparamos os templates usando o método descrito nas seções seguintes para identificar padrões.

3.1. Comparação de minúcias com MH-2d

O método de avaliação de imagens desenvolvido por Carsten Gottschlich (2013) utiliza características únicas de impressões digitais, chamadas minúcias, para avaliar a qualidade de imagens geradas. Denominado MHs (Minutiae histograms), o método compara combinações de minúcias, calculando distâncias e diferenças de ângulos para criar um histograma 2D, o MH-2D. Ao aplicar o método em impressões digitais reais e falsas, os MHs das minúcias são agrupados e comparados com médias específicas de cada categoria. Através da Métrica Wasserstein (EMD), que mede diferenças entre distribuições de probabilidade, é possível determinar se uma impressão digital desconhecida se assemelha mais às genuínas ou às falsas, explorando pequenas diferenças visuais nas médias dos MHs para discernir entre elas.

Observa-se que na Figura 2 foram extraídos respectivamente da esquerda para a direita, acima, um histograma de uma impressão do conjunto de fakes, uma média de todos MHs fake da base de dados (DB4), e abaixo, de uma impressão do conjunto de reais e por fim uma média de todas as impressões reais da base. Há uma sutil diferença entre as duas médias, através dessas pequenas características que classifica-se o desempenho a seguir.

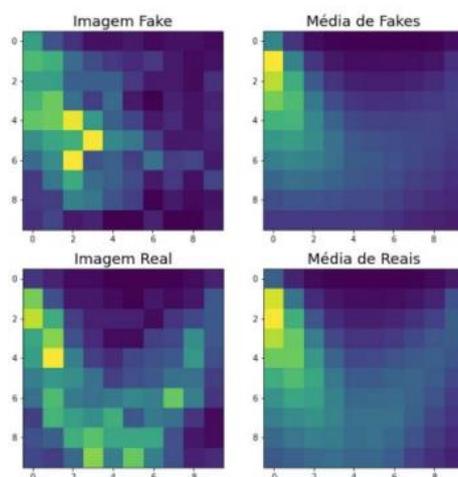


Figura 2. MHs gerados com minúcias dos dados FVC. Os histogramas à esquerda são gerados por um template cada, sendo o superior de uma impressão fake e o inferior real, contendo a distribuição 2d entre as distâncias (eixo horizontal) e ângulos (eixo vertical). À direita os histogramas representam a média entre todos os histogramas fake e reais respectivamente de cima para baixo. Fonte: Autor.

3.2. Resultados experimentais

3.2.1. Comparação entre as imagens (real ou fake)

Observando a Figura 3, temos quatro exemplos gerados pelo sintetizador GAN para os quais iremos ressaltar a presença de características específicas para este tipo de biometria. Para avaliar a confiabilidade das imagens geradas, é necessário examinar detalhes visuais em três níveis de características.

No primeiro nível, macro, observam-se estruturas bem definidas, como deltas e núcleos formando presilhas internas, além de formatos gerais como um arco angular. No segundo nível, destacam-se características locais, como minúcias, especialmente bifurcações e terminações.

Características locais de segundo nível são muito importantes principalmente por serem muito usadas no mercado e podem ser observadas nas imagens da Figura 3, onde foram marcadas, com círculos, algumas minúcias, em que todas as minúcias podem ser descritas a partir de duas principais, terminações e bifurcações. Note que diversas bifurcações estão precisamente visíveis, em alguns casos até, formando os chamados lagos. Muitas terminações também são facilmente detectáveis tornando as imagens aparentemente coerentes conforme este importante nível de detalhes.

O terceiro nível de detalhes, em síntese, costuma ser deixado de lado em muitos sintetizadores, pois apresenta estruturas complexas nas cristas e não é essencial para o reconhecimento mais comum, que se baseia em minúcias. No entanto, em imagens de maior DPI usadas no treinamento, esses detalhes se tornam visíveis.



Figura 3. Exemplo de imagens geradas com a rede treinada contendo marcadores com alguns detalhes importantes. Círculos ressaltam algumas minúcias e Retângulos, estruturas macro igualmente relevantes. Fonte: Autor.

A Figura 4 mostra que o sintetizador imita detalhes semelhantes a diferentes "dedos" e reproduz estilos diversos. Os quatro exemplos da Figura 3 têm características que claramente os diferem entre as formas como foram obtidas. Para uma base melhor, colocamos dois tipos de sensores lado a lado na Figura 4. As imagens reais à esquerda usadas no treinamento e as imagens sintetizadas à direita mantêm características como dimensão, localização, sombras e nível de detalhes. Apesar de distorções da geração artificial perceptíveis por especialistas, as imagens geradas ainda são eficazes para estudos que demandam grande quantidade de dados de impressões digitais.



Figura 4. Exemplo de imagens reais na esquerda e geradas pela GAN na direita. A imagem superior esquerda faz parte do conjunto FVC e pertence a um tipo de sensor. Em sua direita, uma imagem gerada com características do mesmo sensor original. As imagens de baixo seguem a mesma ideia mas com outro tipo de sensor. Fonte: Autor.

3.2.2. Verificar a disposição das minúcias

Usando a técnica proposta por Carsten Gottschlich (2013) para avaliar a confiabilidade do sintetizador usado no estudo atual. Essa avaliação se baseia na distribuição natural das minúcias em impressões digitais, pois certas características dessa distribuição podem diferenciar impressões reais de geradas artificialmente.

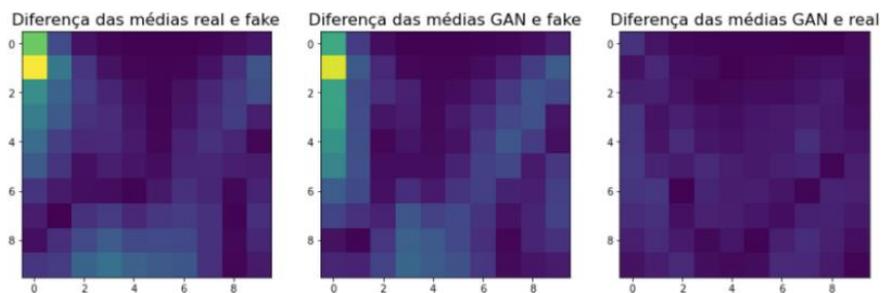


Figura 5. Cálculo diferencial das médias obtidas anteriormente. Fonte: Autor.

A Figura 6 mostra histogramas de minúcias de várias bases e sensores. Comparando-os, padrões consistentes, como o formato de V, são claros nas primeiras colunas. Isso contrasta com a última coluna, onde o formato do V tem ângulo interno maior, além de um padrão mais fraco e disperso. Isso sugere diferenças significativas.

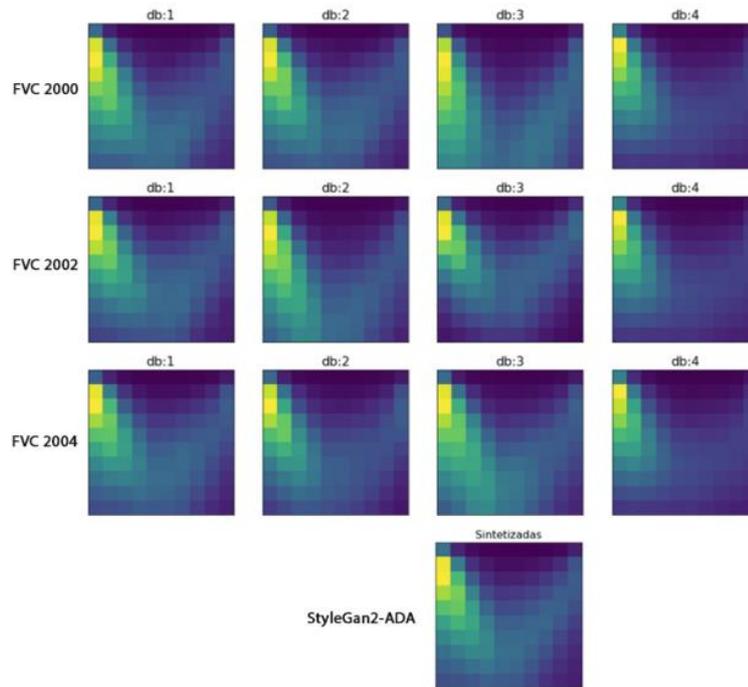


Figura 6. Histograma médio de cada uma das bases FVC, sendo as linhas 1, 2 e 3 pertencentes ao FVC 2000, 2002 e 2004 respectivamente. A última coluna à direita representa a média dos dados gerados pelo SFinge dispostos também no FVC. O último Histograma representa a média dos MH's das imagens gerados pelo nosso sintetizador. Fonte: Autor.

Os histogramas mostram uma relação entre distâncias e ângulos. Foram consideradas distâncias entre minúscias de 0 a 220 pixels, aumentando de cima para baixo, e ângulos de 0 a 180 graus. Portanto, como os histogramas possuem 10x10 bins, cada um desses bins representa 22 pixels de distância da imagem e 18 graus das diferenças direcionais. Sabendo disso, podemos analisar essas distribuições e notar que, em média, existe uma quantidade muito grande de minúscias que estão entre 22 e 88 pixels de distância entre si e que tem uma diferença de ângulos entre 0 e pouco mais de 180. Isso faz muito sentido quando sabe-se que em geral existe uma direção preferencial que as cristas seguem, de modo que, se percorrermos uma pequena distância guiados pela direção predominante de uma região de cristas, muito provavelmente encontraremos, num raio de 22 a 88 pixel, várias minúscias

Entendendo o significado dos histogramas pode ficar mais evidente qual a diferença que existe entre os reais (DB1, DB2 e DB3) e as sintéticas (DB4). Se olharmos a Figura 5, é possível observar melhor as diferenças. Nela temos respectivamente os módulos das diferenças de médias $|\text{reais} - \text{fake}|$ e $|\text{GAN} - \text{fake}|$, em que notamos caminhos diagonais que, tanto a GAN quanto os reais diferem fortemente da base de fakes. No entanto se comparamos, na última imagem, as médias $|\text{reais} - \text{GAN}|$ obtemos muito poucas diferenças. Ao somar todos os bins de cada histograma resultante e multiplicar por um fator de 100 obtemos:

$$100 * \sum |reais - fake|$$

$$= 16; \quad (1) 100 * \sum |GAN - fake|$$

$$= 17; \quad (2) 100 * \sum |reais - GAN|$$

$$= 7. \quad (3)$$

Tudo isso indica de forma ainda mais clara as distâncias existentes. Ainda nas Figuras 7 e 6, notamos que as maiores dessas diferenças são que:

Em imagens reais, para grandes distâncias entre minúcias a probabilidade de se encontrar um par com diferenças de ângulos quase perpendiculares é maior do que para ângulos mais próximos a 0 ou a 180 graus.

Quando a diferença de ângulos entre duas minúcias se aproxima de 180 graus (opostos entre si), as distâncias entre elas tendem a diminuir, isso pode ocorrer pelo fato de minúcias que compartilham um mesmo campo direcional podem ser do tipo terminação tanto no sentido negativo quanto positivo do fluxo, ou seja "indo ou voltando", comportamento que não é muito recorrente em ângulos médios. Nesse caso, para diferenças de ângulos médios, ou seja, próximos de 90 graus, a tendência é que a distância entre eles seja bem maior, pois, dificilmente ocorrerá de uma minúcia estar próxima de outra que possua um sentido abruptamente perpendicular ao sentido padrão do fluxo.

Observemos mais claramente a Tabela 1. Ao combinar e comparar as médias das bases reais do FVC com o EMD, obtém-se um custo médio de distâncias de 62. Quando combinamos os reais com os DB4, claramente nota-se uma certa distância, em que obtivemos um custo médio das distâncias entre reais e DB4 de 117.

Tabela 1. Combinação entre as distâncias dos histogramas médios das bases FVC e da GAN treinada. Última coluna: DB4, dados gerados pelo SFinge contidos no FVC; Penúltima coluna: GAN, Nosso sintetizador treinado usando uma StyleGAN e dados da FVC; Demais colunas, dados reais da FVC. Por questão de espaço os nomes das bases foram abreviados, por exemplo, a base 2002 db1 foi abreviada para 2 db1. Fonte: Autor.

	0 db1	0 db2	0 db3	2 db1	2 db2	2 db3	4 db1	4 db2	4 db3	GAN	DB4
0 db1	-	28	50	43	50	77	51	36	54	32	117
0 db2	-	-	54	26	53	85	44	22	58	42	115
0 db3	-	-	-	71	81	88	68	68	58	48	138
2 db1	-	-	-	-	73	89	28	38	69	20	124
2 db2	-	-	-	-	-	80	81	75	63	71	103
2 db3	-	-	-	-	-	-	111	77	83	74	98
4 db1	-	-	-	-	-	-	-	41	89	21	122
4 db2	-	-	-	-	-	-	-	-	78	44	83
4 db3	-	-	-	-	-	-	-	-	-	50	133
GAN	-	-	-	-	-	-	-	-	-	-	142
DB4	-	-	-	-	-	-	-	-	-	-	-

Sabendo dessa distância, a penúltima coluna nos mostra que o gerador GAN está muito mais próximo dos reais que dos sintéticos com uma média de distâncias de 44, bem abaixo da média dos reais, ou seja, a rede foi capaz de gerar imagens tão reais a ponto de

possuir uma estrutura natural que se aproxima muito bem de todas as amostras de sensores do FVC.

Na Figura 7 observa-se a média de cada uma das classes discutidas até então. Calculando as distâncias entre eles obtemos:

- Distância entre (2) GAN e (1) reais: 19;
- Distância entre (2) GAN e (3) DB4: 142;
- Distância entre (1) reais e (3) DB4: 130.

Finalmente, portanto, é possível usar uma rede neural do tipo GAN com poucos dados para treinamento e obter um resultado tão bom quanto os reais quando analisados usando distâncias e ângulos entre minúsculas. Os custos mínimos calculados entre as distribuições médias das classes mostram que os dados gerados pela GAN, se saíram muito bem, pois, apresentam uma distância até os dados fake maior do que o próprio conjunto de reais.

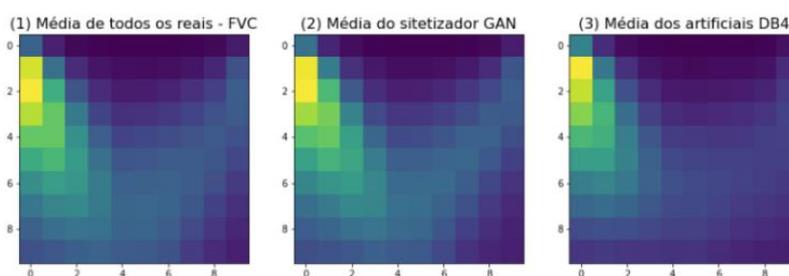


Figura 7. comparação entre as médias de histograma. (1) representa média de todos os histogramas calculados dos reais do FVC; (2) Contém a média dos histogramas sintetizados pela nossa GAN; (3) A média dos histogramas do DB4 (sintéticos gerados pelo SFinge e dispostos nos FVCs). Fonte: Autor.

4. Conclusão

Usando métodos avançados de redes neurais GAN para sintetizar imagens realistas de impressões digitais, mesmo com um conjunto limitado de dados disponíveis, pode-se afirmar que o objetivo foi alcançado. O algoritmo StyleGAN - ADA é utilizado para aumentar a base de dados fornecida pela base FVC, resultando em imagens convincentemente autênticas.

A abordagem emprega MHs para representar a distribuição de características das impressões digitais e a métrica EMD para comparar essas distribuições. Isso leva a uma classificação que comprova a proximidade das imagens geradas com as imagens reais. A rede neural demonstra compreensão dos padrões complexos nas cristas das impressões, inclusive com representações visuais de várias categorias de sensores presentes na base de treinamento. Embora existam algumas distorções inerentes a redes neurais deste tipo, essa abordagem é promissora para a síntese e reconstrução de impressões digitais, mesmo em casos de destruição parcial.

4.1. Trabalhos futuros

O método de sintetizar imagens é recomendado para estudos com detalhes minuciosos e grande base de dados, semelhante à usada no treinamento. Apesar dos resultados positivos, é importante considerar outras formas de validação. Pode-se ampliar o método

de MHs para mais dimensões, aumentando a precisão, porém, sem garantia de resultados tão bons. Os dados gerados são confiáveis, mas para mais precisão, é aconselhável usar uma base de treinamento maior, diferentes métricas de validação e considerar outras variáveis.

Referências

Anil K. Jain, L. H. and Bolle, R. (1997). On-line fingerprint verification, IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE 19(4): 302–314.

Carsten Gottschlich, S. H. (2013). Separating the real from the synthetic: minutiae histograms as fingerprints of fingerprints, IET (Institution of Engineering and Technology) Biometrics 3(4): 291–301.

Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. and Bengio, Y. (2014). Generative adversarial nets, in Z. Ghahramani, M. Welling, C. Cortes, N. D. Lawrence and K. Q. Weinberger (eds), Advances in Neural Information Processing Systems 27, pp. 2672–2680.

Karras, T., Aittala, M., Hellsten, J., Laine, S., Lehtinen, J. and Aila, T. (2020). Training generative adversarial networks with limited data, 2: 37.

Planalto (2018). Lei nº 13.709, de 14 de agosto de 2018: Lei geral de proteção de dados pessoais (lgpd). URL: https://www.planalto.gov.br/ccivil_03/_ato2015-2018/2018/lei/113709.htm

Zhang, H., Zhang, Z., Odena, A. and Lee, H. (2020). Consistency regularization for generative adversarial networks, International Conference on Learning Representations – to appear. URL: <https://openreview.net/forum?id=S1lxKlSKPH>