

## DECIFRANDO DEEPPAKES DE ÁUDIOS: UMA INVESTIGAÇÃO PELA ANÁLISE DE FREQUENCIA

 <https://doi.org/10.56238/arev6n3-375>

**Data de submissão:** 29/10/2024

**Data de publicação:** 29/11/2024

**Maria Stella Simões Piccolo**

Graduanda do Curso de Sistema de Informação da Universidade de Araraquara - UNIARA

Araraquara-SP

E- mail: mssp1717@outlook.com

**João Henrique Gião Borges**

Orientador

Docente do Curso de Sistema de Informação da Universidade de Araraquara-UNIARA. Araraquara

– SP

E-mail: jhgborges@uniara.edu.br

**Fabiana Florian**

Coorientadora

Docente do Curso de Sistema de Informação da Universidade de Araraquara – UNIARA. Araraquara

– SP

E-mail: fflorian@uniara.edu.br

---

### RESUMO

Esta investigação examina a tecnologia emergente dos DeepFakes de áudio, que se apresenta como um desafio contemporâneo. Para tratar deste assunto, empregou-se o ElevenLabs para a clonagem de voz, juntamente com scripts fundamentados em Deep Learning e Machine Learning para a criação de espectrogramas e avaliação de padrões nas frequências das vozes. Os achados indicaram que a avaliação dos gráficos de cada voz é eficiente para diferenciar a voz artificial da verdadeira.

**Palavras-chave:** Inteligência Artificial. DeepFakes. Deep Learning. DeepFakes de Audio. ElevenLabs. Espectograma.

## 1 INTRODUÇÃO

No cenário contemporâneo, caracterizado pelos avanços tecnológicos e pela proliferação da Inteligência Artificial (IA), surge uma nova tecnologia dentro do complexo de *DeepFakes*: as *DeepFakes* de Áudio. Embora seu desenvolvimento tenha sido inicialmente para trazer uma melhora na rotina cotidiana, com o uso dos *audiobooks*, essa tecnologia tem sido usada e explorada para uma manipulação da realidade, representando uma ameaça para a segurança pública.

As *DeepFakes*, são produtos da IA, que fundem, combinam, substituem ou até mesmo sobreposição ou substitui áudios e imagens para criar arquivos falsos. Este artigo, tem como foco o estudo da *DeepFakes* de Áudio, que possui a capacidade de gerar vozes falsas e a clonar vozes existentes e sua análise envolve diversos parâmetros, incluindo frequência, intensidade e outros atributos sonoros.

Este artigo tem o objetivo de estudar o funcionamento das *DeepFakes* de Áudio comparando as frequências das vozes que foram clonadas e da voz real. A utilização das ferramentas ElevenLabs para geração das vozes falsificadas e clonadas e dos Espectrogramas para uma visualização gráfica da frequência das vozes, contribuíram na identificação precisa das *DeepFakes* de Áudio, distinguindo uma voz da outra.

De acordo com o site UOL notícias (2024), o avanço na utilização das *DeepFakes*, especialmente na manipulação de áudios, gera preocupações crescentes sobre suas consequências. Muitas pessoas ainda não possuem compreensão suficiente sobre essa temática que pode levar a situações problemáticas, como golpes e em casos recentes manipulações nas eleições. Nesse site relatase alguns usos de *DeepFakes*, em um caso específico um dos alvos foi Joe Biden, atual presidente dos Estados Unidos, que passou por esse problema de *DeepFakes* de áudio em uma eleição nos Estados Unidos, onde um áudio simulando sua voz foi circulado, ilustrando a ameaça à integridade do processo democrático.

Tendo em vista esses desafios, percebe-se a necessidade da compreensão das *DeepFakes* de Áudio e de desenvolver métodos de análise ou aprimorar as já existentes permitindo a possibilidade de discernir vozes autênticas e falsificadas, contribuindo para uma tentativa de diminuir os riscos associados aos usos indevidos.

Segundo Almutairi, Z., & Elgibreen, H. (p.2, 2022). “A detecção de *DeepFakes* de áudio tornou-se, portanto, uma área ativa de pesquisa com o desenvolvimento de técnicas avançadas e métodos de Deep Learning (DL). No entanto, com tais avanços, os métodos atuais de DL estão enfrentando dificuldades, e uma investigação adicional é necessária para entender em qual área da detecção de *DeepFakes* de áudio precisa de mais desenvolvimento. Além disso, uma análise comparativa dos

métodos atuais também é importante, e, até onde sabemos, falta na literatura uma revisão dos métodos de detecção de áudio imitados e gerados sinteticamente (Tradução nossa).”

A hipótese deste artigo é que a utilização das ferramentas ElevenLabs e Espectrogramas permitirão distinguir com eficiência algumas questões que nortearão a pesquisa são que em cada voz há diferentes níveis de frequências, por meio da frequência pode-se realizar uma análise comparativa entre cada voz. Para testar essa hipótese, será utilizada ferramenta como Espectrogramas que serve como um gráfico que demonstra as frequências das vozes por meio de desenhos de ondas sonoras.

Para iniciar essa pesquisa é necessário primeiro entender o que é *DeepFakes*? Como funciona a *DeepFakes* de Áudio? Como se analisa a frequência de voz? O Espectrograma irá ser diferente entre uma voz real e a voz clonada? Para responder tais questionamentos foi realizado uma leitura de diferentes artigos que abordam sobre o que é essa tecnologia *DeepFakes*, será estudado como funciona essa *DeepFakes* de Áudio, haverá a utilização da ferramenta ElevenLabs para realizar a clonagem das vozes, para a realização da análise, será desenvolvido um script que receberá esses arquivos de áudios e os representará em forma de Espectrogramas, ou seja, em uma forma gráfica, onde serão formadas ondas que representam as frequências, para realizar a comparação.

## 2 PESQUISA BIBLIOGRÁFICA

Esta seção aborda os conceitos de Inteligência Artificial, *Deep Learning*, *DeepFakes*, *DeepFakes* de áudio, (2.3) Frequência de voz, (2.4) Potencial da ElevenLabs na clonagem de voz, (2.5) Relação do espectrograma e da frequência.

### 2.1 INTELIGÊNCIA ARTIFICIAL (IA)

Para ter uma compreensão melhor do tema deste artigo, é necessário primeiro entender a sua estrutura, como já relatado, a *DeepFakes* uma tecnologia formada através da inteligência artificial usando uma metodologia chamada de *Deep Learning*, tendo isso em vista, como podemos descrever a IA?

Segundo Jaime Simão Schiman (2021), “O domínio de IA se caracteriza por uma coleção de modelos, técnicas e tecnologias (busca, raciocínio e representação de conhecimento, mecanismos de decisão, percepção, planejamento, processamento de linguagem natural, tratamento de incertezas, aprendizados de máquinas) que, isoladamente ou agrupadas, resolvem problemas de tal natureza.”

Já a Autora Priscila Mello Alves (2020), diz que “As definições de IA encontradas na literatura científica, enquanto disciplina do conhecimento humano, são categorizadas, sendo ou empiricamente com formulação de hipóteses e confirmações experimentais ou teoricamente envolvendo cálculos

matemáticos. Na ótica da categoria empírica há perspectiva de os sistemas pensarem como seres humanos, possibilitando o aprendizado com experiências, enquanto no enfoque teórico esperam-se ações lógicas que incluem capacidade de dedução e inferência sobre novas relações”.

Tendo em vista essas duas definições, percebe-se que a IA, é uma tecnologia, cujas definições variam muito, mas que em sua base, podemos denominar como uma tecnologia que abrange diversos modelos, que em seu entorno pode comportar-se como humana, no sentido que pode aderir técnicas de aprendizagem como *machine learning* ou *deep learning*, cognição e tomadas de decisão como rede neurais, dentre outras, tornando -se uma maneira de otimizar processos, automatizar funções e diminuir a complexidade.

### 2.1.1 deep learning – (aprendizado profundo)

Segundo o site da IBM, “*Deep Learning* é um subconjunto de aprendizado de máquina, que é essencialmente uma rede neural com três ou mais camadas. Essas redes neurais tentam simular o comportamento do cérebro humano, embora longe de corresponder a sua capacidade, permitindo que ele “aprenda” com grandes quantidades de dados. Embora uma rede neural com uma única camada ainda possa fazer previsões aproximadas, camadas ocultas adicionais podem ajudar a otimizar e refinar a precisão.”

Aprendizado Profundo oferecem atualmente um importante conjunto de métodos para analisar sinais como áudio e fala, conteúdos visuais, incluindo imagens e vídeos, e ainda conteúdo textual.” (Ponti Moacir e Costa Gabriel, 2017, 1, p. (63-93), “Como funciona Deep Learning”).

Com as descrições desses autores, nota-se que a IA, não é uma tecnologia consolidada por si só, ela abrange diversas outras para determinadas funções, no caso deste artigo, a *Deep Learning* será algo presente, visto que teremos que realizar uma análise referente as vozes gravadas e criadas.

## 2.2 DEEPFAKES

“O termo DeepFakes refere-se às mídias sintéticas nas quais imagens ou sons capturados de determinadas pessoas são substituídos pelos de outras por meio de técnicas avançadas de aprendizagem de máquina e Inteligência Artificial (IA), com a finalidade de manipular conteúdo visuais e/ou sonoros, com enorme potencial de falseamento da realidade. Celebidades e políticos têm sido os alvos preferenciais dessas manipulações, que têm se popularizado exponencialmente até mesmo por meio de aplicativos gratuitos de celular.” (Fonseca, p.106, FANAYA, fevereiro/2021).

“DeepFakes são, essencialmente, identidades falsas criadas com o deep learning (aprendizado profundo) por meio de um uso maciço de dados” (Spencer, Michael K., tradução: Gabriela Leite, 2019, outras palavras).

Segundo o site CNN (2024), as *DeepFakes* ocorrem quando a inteligência artificial (IA), funde, combina, substitui ou sobrepõe áudios e imagens para criar arquivos falsos em que pessoas podem ser colocadas em qualquer situação, dizendo frases nunca ditas ou assumindo atitudes jamais tomadas. O conteúdo pode ser de caráter humorístico, político ou mesmo pornográfico. São inúmeras as possibilidades: troca de rostos, clonagem de voz, sincronização labial a uma faixa de áudio diferente da original, entre outras. A técnica comumente distorce a percepção a respeito de um indivíduo em uma determinada situação.

Ao seguir algumas definições entendemos que as *DeepFakes* vêm da junção de “*Fake News*” com a tecnologia *Deep Learning* por meio da inteligência artificial, onde através de seu uso, podemos criar conteúdo sintéticos, podendo ser imagem, vídeo e áudio, como explícito no tema, onde os dados armazenados são utilizados por um algoritmo de *Machine Learning* e *Deep Learning*.

### 2.2.1 deepfakes de áudio

Dentre todo esse avanço de tecnologia, aumento crescente do uso da inteligência artificial e consequentemente novos surgimentos de *DeepFakes*, surge a *DeepFakes* de Áudio, que é o foco central deste artigo.

Segundo Almutairi, Z., & Elgibreen, H. (p-3, 2022). Ferramentas sintetizadas por IA foram recentemente desenvolvidas com capacidades de gerar vozes convincentes. No entanto, embora essas ferramentas tenham sido introduzidas para ajudar as pessoas, elas também foram usadas para espalhar desinformação pelo mundo usando áudio, e seu mau uso mal-intencionado levou ao medo do “*DeepFakes* de Áudio” (tradução nossa).

“DeepFakes de Áudio concentram-se na geração da voz do orador alvo, usando técnicas de aprendizado profundo para retratar o orador dizendo algo que não foi dito. As vozes falsas podem ser geradas usando síntese de texto para fala (TTS) ou conversão de voz (VC)” (tradução nossa). (Masood, M., Nawaz., Malik, K.M., Ali, J. & Irtaza A. Deepfakes Generation and Detection: State-of-the-art, open challenges, countermeasures, and way forward. p (1- 54), Cornell University, 2021.)

A *DeepFakes* de Áudio funciona através de uma tecnologia onde se é possível clonar a sua voz, através de uma conversão de voz que se baseia em alguns codificadores, do tipo rede neural que vai comprimir os dados de entrada em uma representação compacta e interna, e acaba aprendendo a

descompactar esses dados dessa representação para restaurar os dados originais, dessa maneira ela aprende a apresentar os dados em um formato compacto enquanto destaca informações importantes.

Focando nos estudos sobre *DeepFakes* de Áudio, percebemos o uso de técnicas avançadas de inteligência artificial, especificamente *Deep Learning* e *Machine Learning*, para clonar a fala de uma pessoa de maneira natural e convincente. A plataforma utilizada para a clonagem de voz e as etapas para a clonagem serão descritas a seguir:

### 2.3 FREQUÊNCIA DE VOZ

Para produzir a voz, primeiro, o ar que está sendo expirado deve passar pelas cordas vocais e vibrá-las (tente falar durante a inspiração e veja como é difícil). As cordas vocais são estruturas musculomembranasas que formam um V invertido(...). Se as pregas vocais estiverem relaxadas, o ar passará livremente sem produzir som. Quando desejamos falar, o cérebro envia comandos nervosos para os músculos que controlam a tensão das cordas vocais e o ar passará vibrando as pregas. As vibrações são muito rápidas, cuja frequência é de mais 100 vezes por segundo. Enquanto ocorre a vibração, várias estruturas (cavidades da boca, garganta e a passagem nasal) entram em ressonância produzindo várias ondas harmônicas e amplificando o som. (Nishida, M. S., Weber, S. A. T., Oliveira, F. A. K. de, & Troll, J. Voz Humana).

Entendendo o funcionamento da voz, temos a percepção que o som que emitimos pode ser distinguido conforme as movimentações das pregas vocais, o que pode gerar algumas características diferentes. Em uma análise de voz, podemos distinguir uma voz das outras, pela altura, intensidade e amplitude. Na altura verificamos se o som é agudo ou grave, o que é determinado pela frequência da onda, o timbre é distinguido através das ondas sonoras e a intensidade é medida pelo volume, onde um som mais intenso, forte ou fraco vem de um fator denominado amplitude da onda, onde quanto maior a amplitude de uma onda, maior é a pressão que ela irá exercer no ar, o que faz com que nossos tímpanos vibrem de maneira mais intensa.

Vale ressaltar que nós não ouvimos nossa voz da mesma maneira que outra pessoa, por conta que quem está nos ouvindo não nos escuta por intermédio da via aérea, logo, a nossa própria voz não passa por alteração de pressão, o que se conclui que a voz gravada é considerada a representação verdadeira da nossa voz.

### 2.4 POTENCIAL DA ELEVENLABS NA CLONAGEM DE VOZ

A utilização de ferramentas como ElevenLabs contribuiu muito para este artigo, devido a sua capacidade de proporcionar a possibilidade de clonagem de voz, tendo em vista seu crescimento, muitas pessoas passaram a utilizar para brincadeiras de trolagem, criação de vozes sintéticas e até


mesmo para tentativas de aplicação de golpes. Apesar de ElevenLabs ser uma plataforma paga, ela fornece recursos gratuitos como criação de vozes sintéticas.

De acordo com as informações do site Kaspersky Daily (2023). “A conversão de voz é baseada em codificadores automáticos, um tipo de rede neural que comprime os dados de entrada (parte do codificador) em uma representação interna compacta e, então, aprende a descompactá-los dessa representação (parte do decodificador) para restaurar os dados originais.

Desta forma, o modelo aprende a apresentar os dados em um formato compactado enquanto destaca as informações mais importantes.”

Como sugere a imagem disponibilizada neste mesmo site. Encontrada na figura 1.


Figura 1: Esquema Codificador Automático:



Fonte: Kaspersky Daily (2023)

O processo de criação dessas *DeepFakes*, geralmente envolve ao menos duas gravações de áudios que são alimentadas no modelo. A segunda gravação é convertida para parecer com a primeira e após isso o codificador de conteúdo determina o que foi dito a partir desta primeira gravação. O codificador extrai as características da voz, como timbres, entonação, sotaques, frequências, amplitudes da segunda gravação, essas representações são combinadas para a produção do resultado por meio do decodificador.

Figura 2- Processo de geração da voz das *DeepFakes*:



Fonte: Kaspersky Daily

Plataformas como ElevenLabs, entre outras que oferecem essa possibilidade de clonar vozes utiliza-se desses processos, juntamente com a utilização de algoritmos de inteligência artificial como *Machine Learning* e *Deep Learning*.

## 2.5 RELAÇÃO DO ESPECTROGRAMA E DA FREQUÊNCIA

Tendo em vista que a *DeepFakes* de Áudio, possui essa capacidade de clonagem de voz, criação de áudio sintético e entendendo que a nossa voz produz uma certa frequência, para representá-la surge a necessidade de analisá-la e o espectrograma é uma técnica que possibilita essa visualização gráfica.

Segundo o site, Your Physicist, 2024, o Espectrograma é uma técnica que combina a análise de Fourier com o tempo para visualizar as características espectrais de um sinal ao longo do tempo. Ele representa graficamente a intensidade de cada componente de frequência em função do tempo, fornecendo uma representação visual clara das mudanças no conteúdo espectral ao longo do sinal.

Essa técnica é amplamente utilizada em áreas como análise de áudio, processamento de fala, monitoramento de vibrações e análise de sinais não estacionários. O Espectrograma permite identificar mudanças transientes ou eventos de curta duração, além de fornecer informações sobre as características de frequência dominantes em diferentes momentos do sinal.

Este artigo visa utilizar o Espectrograma como uma das ferramentas para analisar as frequências emitidas pelos áudios, visando ter uma perspectiva das diferenças, para uma melhor detecção de áudios fakes e clonagem.

## 3 DESENVOLVIMENTO

Nesta seção apresenta: Utilização da plataforma ElevenLabs para a clonagem da voz, conversão do arquivo MP3 para WAV e foi desenvolvido um script para gerar o espectrograma de frequência, um outro script para aprender os padrões dos espectrogramas e por último um script para análise das diferenças entre uma voz real e uma voz clonada.

### 3.1 ELEVENLABS

Segundo o site ComunitIA (2023), ElevenLabs é uma inovadora empresa de tecnologia que tem como principal produto o áudio gerado por inteligência artificial. Ela traz ferramentas avançadas para criadores e editoras que buscam aprimorar suas narrativas, oferecendo vozes cativantes, emotivas e realistas.


Neste trabalho foi utilizado o site do ElevenLabs, a ferramenta VoiceLabs, para a clonagem das vozes. O processo envolve a gravação das vozes desejadas, a escrita de uma frase para a voz clonada, análise e aprimoramento para tornar o áudio mais natural, e finalmente, o download do áudio gerado.

### 3.2 PROCESSO DE CRIAÇÃO DE *DEEPAKES* DE ÁUDIO PELA PLATAFORMA ELEVENLABS

#### 3.2.1 coleta de dados

No site do ElevenLabs, em VoiceLab encontrado na seção "Voices". Para iniciar a clonagem, foi selecionado uma das bibliotecas previamente criadas e foi adicionado os áudios. Demonstrado na figura 3.

Figura 3 Plataforma VoiceLabs



Fonte: ElevenLabs (2024)


Ao selecionar a voz intitulada como “Pastora”, a seguinte interface é exibida. Encontrada na figura 4 e figura 5.

Figura 4- Adicionando os áudios da voz da pastora



Fonte: ElevenLabs (2024)

Figura 5 – Inserindo um texto para ser gerado com essa voz:



Fonte: ElevenLabs (2024)

Após clicar em "Generate Speech" demonstrado na Figura 5, o áudio é gerado. Esse áudio é gerado através da técnica de *Deep Learning* para processar o texto e então gerar o áudio realista, como foi inserido arquivos com a voz original, esse volume de dados foi processado e treinado para capturar nuances, pausas e o ritmo natural da fala. É possível ajustar o áudio para que a voz se torne ainda mais parecida com a natural. Depois de ajustar, clicamos no botão de download.

### 3.2.2 convertendo mp3 para wav

Depois de gerar a voz clonada, utilizado um algoritmo criado pelo autor que recebe os arquivos de áudio e gera um espectrograma. Mas para isso, será necessário que haja a conversão do arquivo MP3 para a extensão WAV. Para isso foi utilizado um site chamado Convertio, que faz isso de maneira gratuita. Como é demonstrado na figura 6.

Figura 6 - Conversor de MP3 para WAV:



Fonte: Convertio

#### 4 GERANDO ESPECTROGRAMA ATRAVÉS DO ÁUDIO WAV

A figura 7, tem como função gerar um gráfico denominado espectrograma, por meio do arquivo MP3 convertido para extensão WAV. Tendo em vista o objetivo do algoritmo, deve-se entender o seu funcionamento, que se baseia em alguns passos como: Importação das bibliotecas; Leitura de Arquivo de áudio; Normalização dos dados do áudio; Cálculo da transformada de Fourier e por fim a plotagem do espectro de frequência. Esse código é encontrado na Figura 7.

Figura 7 – Script Espectrograma

```
E Espectrograma Version control main
1 import numpy as np
2 from scipy.io import wavfile
3 import matplotlib.pyplot as plt
4
5 sample_rate, audio_data = wavfile.read('Voz-Clonada-pastora (1).wav')
6 audio_data = audio_data.astype(float) / 2**15
7
8 fft_data = np.fft.fft(audio_data)
9 freq = np.fft.fftfreq(len(audio_data), 1/sample_rate)
10
11 plt.plot(*args: freq, np.abs(fft_data))
12 plt.xlabel('Frequência (Hz)')
13 plt.ylabel('Amplitude')
14 plt.title('Espectro de Frequência - Voz Clonada Pastora')
15 plt.show()
16
```

Fonte: Autor (2024)

##### 4.1 IMPORTAÇÃO DAS BIBLIOTECAS

As bibliotecas importadas são `numpy`, `scipy.io.wavfile`, `matplotlib.pyplot`. Demonstradas na Figura 8.

Figura 8 – Importação das bibliotecas

```
1 import numpy as np
2 from scipy.io import wavfile
3 import matplotlib.pyplot as plt
4
```

Fonte: Autor (2024)

Cada biblioteca tem uma funcionalidade específica, sendo a *Numpy* utilizada para operações numéricas eficientes, *scipy.io.wavfile* para ler e escrever arquivos WAV e a *matplotlib.pyplot* criação de gráficos.

## 4.2 LEITURA DE ARQUIVO

Nessa parte do algoritmo, é realizada uma leitura do arquivo, usando os seguintes conceitos: `sample_rate`; `audio_data`, `wavfile.read()`. Como demonstrada na figura 9.

Figura 9 – Leitura de arquivo

```
5 sample_rate, audio_data = wavfile.read('Voz-Clonada-pastora (1).wav')
```

Fonte: Autor (2024)

A função `wavfile.read()` lê um arquivo WAV e retorna duas informações a taxa de amostragem (`sample_rate`) e os dados do áudio (`audio_data`).

A variável `sample_rate` – É a taxa de amostragem do áudio, indicando quantas amostras por segundo foram capturadas e a `audio_data` é um array contendo os dados do áudio.

## 4.3 NORMALIZAÇÃO DOS DADOS DO ÁUDIO

Nessa etapa do código, é realizada a conversão da extensão MP3 para WAV e a normalização dos dados do áudio. Demonstrada na Figura 10.

Figura 10 – Normalização dos dados do áudio e conversão das extensões

```
6 audio_data = audio_data.astype(float) / 2**15
7
```

Fonte: Autor (2024)

A variável `audio_data.astype(float)` converte os dados do áudio para o tipo float e `audio_data / 2**15` normaliza esses dados do áudio. Em arquivos WAV com 16 bits por amostra, os valores variam de -32768 a 32767. A divisão por  $2^{15}$  (32768) normaliza os dados para o intervalo de -1 a 1.

#### 4.4 CÁLCULO DA TRANSFORMADA DE FOURIER

Nessa parte do código é realizado o cálculo da transformada de Fourier, cuja aplicabilidade é dividir algo em várias ondas senoidais. A Transformada de Fourier é uma ferramenta poderosa para converter um sinal do domínio do tempo para o domínio da frequência, permitindo a identificação de componentes de frequência que não são visíveis diretamente no sinal original. Essa parte é encontrada na Figura 11.

Figura 11 – Cálculo da transformada de Fourier

```
8   fft_data = np.fft.fft(audio_data)
9   freq = np.fft.fftfreq(len(audio_data), 1/sample_rate)
10
```

Fonte: autor (2024)

Nesse código `np.fft.fft(audio_data)` calcula a Transformada de Fourier dos dados do áudio, transformando o sinal do domínio do tempo para o domínio da frequência. A variável `fft_data` contém os coeficientes da transformada.

Já a `np.fft.fftfreq(len(audio_data), 1/sample_rate)`, gera uma lista de frequências correspondentes aos coeficientes da Transformada de Fourier onde `len(audio_data)` é o número de amostras, e `1/sample_rate` é o intervalo de tempo entre as amostras.

#### 4.5 PLOTAGEM DO ESPECTRO DE FREQUÊNCIA

Nessa parte final do código é onde é desenvolvida a parte da plotagem do espectro da frequência. Mostrado na Figura 12.

Figura 12 – Plotagem do Espectro de frequência

```
11  plt.plot(*args: freq, np.abs(fft_data))
12  plt.xlabel('Frequência (Hz)')
13  plt.ylabel('Amplitude')
14  plt.title('Espectro de Frequência - Voz Clonada Pastora')
15  plt.show()
16
```

Fonte: Autor (2024)


A função `plt.plot(freq, np.abs(fft_data))` plota o espectro de frequência, utilizando as frequências (`freq`) no eixo x e a magnitude dos coeficientes da Transformada de Fourier (`np.abs(fft_data)`) no eixo y. A variável `plt.xlabel('Frequência(Hz)')` define o rótulo do eixo x como "Frequência (Hz)". As variáveis `plt.ylabel('Amplitude')` define o rótulo do eixo y como "Amplitude". Já

a função `plt.title` ('Espectro de Frequência - Voz Clonada Pastora'): Define o título do gráfico e por último a função `plt.show()` vai exibir o gráfico.

## 5 GRÁFICO ESPECTROGRAMA

Ao realizar os procedimentos acima, e gerar os gráficos com a voz clonada e com a voz original, foi obtido os seguintes resultados, Figura 13 e Figura 14.

Figura 13 e Figura 14 – Gráfico Espectro de frequência- Voz original e voz clonada da Pastora




Considerando essas duas imagens (Figuras 13 e 14), podemos fazer a seguinte análise, avaliando as frequências da voz original, como demonstra a figura 13, nota-se uma maior diversidade no que chamamos de componentes harmônicos, contendo picos de amplitude moderados distribuídos por amplas faixas de frequências, sendo elas tanto positivas quanto negativas. A voz clonada apresenta um espectro altamente concentrado, tendo dois picos proeminentes bem próximos de 0 Hz e as amplitudes maiores. Isso significa que nesse caso a clonagem reduziu a riqueza harmônica da voz, deixando de maneira condensada sua energia em uma faixa de frequência restrita.

### 5.1 TESTANDO TIMBRES DE VOZ


No tópico 3.2.1 coleta de dados, na figura 3 VoiceLabs, utilizamos um áudio denominado “pastora”, agora será utilizado a voz intitulada “Aryane - Cantora”, na Figura 15 e depois foi inserido o texto, na Figura 16.

Figura 15 - Voz Aryane -Cantora





Fonte: ElevenLabs (2024)

Figura 16 – Inserindo texto para a voz Aryane -Cantora



Fonte: ElevenLabs

Figura 17 e Figura 18 – Voz Original e Clonada respectivamente.



Na análise das figuras 17 e 18, percebemos que ambas as imagens demonstram que a maior parte da energia está concentrada em frequências baixas, perto de 0 Hz, dando a perspectiva que os sinais dos áudios são similares em questão de conteúdo de frequência básico. A figura 18 (Voz clonada Ary), indica que ela foi simplificada ou possui um alcance dinâmico menor em comparação a figura 17 (Voz Original Ary), um outro ponto é que os picos de amplitude presentes na figura 18 (Voz clonada Ary), replicam as características principais da voz original, mas se perde na fidelidade ou alcance dinâmico, conforme indicado pela amplitude menor e as limitações representadas nas frequências.

## 5.2 CÓDIGO PARA ANÁLISE DE PADRÃO DO ESPECTROGRAMA

Após clonar as vozes, converter para o formato WAV e gerar os espectrogramas várias vezes, surgiu a necessidade de criar um script para realizar a análise de padrão sonora e gerar novos espectrogramas. As figuras abaixo (19-21) mostram o script completo:

Figura 19 – Primeira parte do código análise e criação de espectrogramas

```

14 # Função para aplicar variações ao áudio
15 def augment_audio(data, sample_rate):
16     augmented_data = []
17
18     # Variações de pitch
19     for pitch_shift in np.linspace(-5, stop=5, num=10):
20         augmented_data.append(librosa.effects.pitch_shift(data, sr=sample_rate, n_steps=pitch_shift))
21
22     # Variações de velocidade
23     for speed_change in np.linspace(start=0.8, stop=1.2, num=10):
24         augmented_data.append(librosa.effects.time_stretch(data, rate=speed_change))
25
26     # Adicionar ruído
27     for noise_factor in np.linspace(start=0.001, stop=0.05, num=10):
28         noise = np.random.randn(len(data))
29         augmented_data.append(data + noise_factor * noise)
30
31     # Combinações de augmentações (pitch + speed)
32     for pitch_shift in np.linspace(-2, stop=2, num=5):
33         for speed_change in np.linspace(start=0.9, stop=1.1, num=4):
34             aug_data = librosa.effects.pitch_shift(data, sr=sample_rate, n_steps=pitch_shift)
35             aug_data = librosa.effects.time_stretch(aug_data, rate=speed_change)
36             augmented_data.append(aug_data)
37
38     return augmented_data
39

```

Fonte: Autor (2024)

Figura 20 – Segunda parte do código de análise e criação de espectrogramas

```

1 import numpy as np
2 import matplotlib.pyplot as plt
3 import librosa
4 import librosa.display
5 import os
6
7 # Carregar o arquivo de áudio original
8 audio_data, sample_rate = librosa.load(path: 'VozTestePastoraOriginal.wav', sr=None)
9
10 # Criar uma pasta para armazenar os espectrogramas gerados
11 output_dir = 'espectrogramas - Voz Original Pastora teste1'
12 os.makedirs(output_dir, exist_ok=True)
13
14 # Função para aplicar variações ao áudio
15 def augment_audio(data, sample_rate):
16     augmented_data = []
17
18     # Variações de pitch
19     for pitch_shift in np.linspace(-5, stop: 5, num=10):
20         augmented_data.append(librosa.effects.pitch_shift(data, sr=sample_rate, n_steps=pitch_shift))
21
22     # Variações de velocidade
23     for speed_change in np.linspace(start: 0.8, stop: 1.2, num=10):
24         augmented_data.append(librosa.effects.time_stretch(data, rate=speed_change))
25
26     # Adicionar ruído
27     for noise_factor in np.linspace(start: 0.001, stop: 0.05, num=10):
  
```

Fonte: Autor (2024)

Figura 21 – Última parte do código de análise e criação de espectro


```

15 def augment_audio(data, sample_rate):
16     return augmented_data
17
18 # Gerar espectrogramas
19 count = 0
20 augmented_audios = augment_audio(audio_data, sample_rate)
21 for i, aug_data in enumerate(augmented_audios):
22     if count >= 100: # Limitar a 100 espectrogramas
23         break
24
25 # Calcular o espectrograma usando STFT
26 plt.figure(figsize=(10, 4))
27 D = librosa.amplitude_to_db(np.abs(librosa.stft(aug_data, n_fft=2048, hop_length=512)), ref=np.max)
28 librosa.display.specshow(D, sr=sample_rate, x_axis='time', y_axis='log')
29 plt.colorbar(format='%+2.0f dB')
30 plt.title(f'Espectrograma - Voz original Pastora - teste2 - Gráfico {i + 1}')
31 plt.savefig(f'{output_dir}/espectrogramaVozOriginalPastora2_{i + 1}.png')
32 plt.close()
33
34 count += 1
35
36 print(f'{count} espectrogramas gerados e salvos na pasta "{output_dir}."')
  
```

Fonte: Autor (2024)

Depois de colocar os áudios das vozes originais e das vozes clonadas da “Pastora da Cantora Aryane”, foram criados alguns diretórios para os respectivos áudios, com cerca de 50 imagens de espectrogramas em cada diretório. A Figura 22, abaixo, ilustra esse processo:


Figura 22 – Programa com os diretórios criados:



Fonte: Autor (2024)


Nota-se que a cada áudio processado, um diretório com diversas imagens de espectrogramas é criado. Esses espectrogramas são gerados com base nas transformações aplicadas ao sinal de áudio, sendo representados visualmente pelas variações de frequência ao longo do tempo. Como demonstrado nas figuras 23 e 24.

Figura 23 e Figura 24 – Espectrogramas da voz original da “Pastora”



Esses gráficos visualizam a intensidade das frequências de um sinal de áudio ao longo do tempo. As diferenças encontradas estão presentes no tempo total, onde a figura 23, espectrograma da voz original da pastora, cobre em torno de 14 segundos, já a da figura 24, espectrograma da voz original da pastora, cobre em torno de 22 segundos. Nas características visuais apresenta as faixas coloridas, semelhantes, indicando que se tratado mesmo áudio. Com tudo, apresenta pequenas diferenças nas distribuições das frequências mais altas em torno de 4096 Hz e acima, e na densidade das faixas em algumas regiões.


Figura 27 e Figura 28 – Espectrogramas da voz original “Aryane Cantora”



Nas figuras 27 e 28, esses gráficos apresentam escala de cor onde indica a intensidade do sinal em dB (decibéis), onde os tons claros representam maior intensidade e os escuros, menor intensidade. As frequências dominantes nos dois gráficos são similares, elas estão em 128 Hz e 1024 Hz, com componentes harmônicos em intervalos mais altos, o que é comum e fundamentais nas falas humanas. Na amplitude e energia, as duas figuras representam áreas com maior intensidade concentradas entre 128 Hz e 1024 Hz. Algo interessante encontrado nos componentes repetidos é que existem padrões repetidos que aparentemente ocorrem ciclicamente, onde é encontrado em fonemas ou sílabas no sinal de voz.

### 5.3 COMPARAÇÃO DOS ESPECTROGRAMAS

Figura 30 e Figura 31 – Espectrogramas voz original e clonada da “Pastora”




Fonte: Autor (2024)

Fonte: Autor (2024)

Ao analisar as figuras 30 e 31, nota-se que ambas as imagens possuem padrões de frequências bem parecidas, onde possuem pequenas variações por se tratar de uma voz original e a outra clonada.

As faixas de frequências principais, possuem em torno de 64 Hz a 4096 Hz, contendo uma intensidade e um padrão visual similares. Outras diferenças presentes é que na figura 30, que se trata da voz original, a “energia” presente é ligeiramente mais uniforme, enquanto a figura 31, voz clonada, possui uma variação leve nos harmônicos, as diferenças nas intensidades e nos detalhes de padrões de frequência podem sugerir que a voz clonada apresenta leves distorções.

Figura 32 e Figura 33 – Espectrogramas voz original e clonada da “Aryane Cantora”



As duas figuras, mostram padrões semelhantes, demonstrando a eficácia da clonagem da voz, essa eficácia ocorre principalmente porque ela consegue manter as características harmônicas da gravação original. As diferenças mais aparentes se encontram nas pequenas variações na intensidade em algumas faixas de frequência e pequena duração da voz clonada.



Figura 39 - Fonte: Autor (2024)


```

100 # Normaliza as características
101 scaler = StandardScaler()
102 X_train = scaler.fit_transform(X_train)
103 X_test = scaler.transform(X_test)
104
105 # Treina o classificador SVM
106 clf = SVC(kernel='linear', random_state=42)
107 clf.fit(X_train, y_train)
108
109 # Prever no conjunto de teste
110 y_pred = clf.predict(X_test)
111
112 # Avalia o modelo
113 print("Matriz de Confusão:")
114 print(confusion_matrix(y_test, y_pred))
115 print("\nRelatório de Classificação:")
116 print(classification_report(y_test, y_pred, target_names=['Clonada', 'Original']))
117
118 # Exibi e salva algumas imagens e suas representações HOG
119 print("Salvando imagens clonadas e suas representações HOG:")
120 salvar_imagens_com_hog(diretorio_clonadas, pasta_saida='output_clonadas')
121
122 print("Salvando imagens originais e suas representações HOG:")
123 salvar_imagens_com_hog(diretorio_originais, pasta_saida='output_originais')
124
  
```

## 6 RESULTADOS


Com o uso do script encontrado no tópico 5.2 e mostrados nas figuras 34-39, obtém-se os seguintes resultados, como sugere as figuras 40 - 44.

Figura 40 – Resultado do script.



Fonte: Autor (2024)


Figura 41 e Figura 42 – Imagem HOG – Voz Clonada



Fonte: Autor (2024)

Fonte: Autor (2024)

Figura 43 e Figura 44 – Imagem HOG – Voz Original



Fonte: Autor

Fonte: Autor

A figura 40, nos retorna uma matriz de confusão, que basicamente é uma tabela onde se é possível visualizar o desempenho do modelo em relação as classes, clonadas e original. No script ele retorna  $[40 \ 0]$ , que significa que o modelo classificou corretamente 40 amostras da classe “Clonada” corretamente, e  $[0 \ 40]$ , que significa que o modelo classificou 40 amostras da classe “Original” sem cometer erros.

Abaixo da matriz de confusão, também foi retornado um relatório de classificação, onde as métricas apresentam um valor de 1.00 para ambas as classes, ou seja, o desempenho foi considerado perfeito. Os aspectos avaliados foram *Precision* (Precisão): 1.00 para “Clonada” e 1.00 para “Original”, *Recall* (Revocação): 1.00 para ambas as classes, o que indica que todas as amostras de cada classe foram identificadas corretamente. *F1-Score*: 1.00 para ambas as classes, indicando uma harmonia perfeita entre a precisão e o *recall* e por último na acurácia total obteve um resultado de 100% num total de 80 amostras.

As figuras 41 a 44, representam imagens em HOG (*Histogram of Oriented Gradients*), que é uma técnica de extração de características que captura informações de textura e contornos das imagens utilizadas em uma visão computacional. O que pode indicar que o sistema está registrando as representações para uma possível análise posterior, ou reutilização em novos testes, ou seja, está aprendendo os padrões das imagens.

## 7 CONCLUSÃO

Esta pesquisa analisou a habilidade de diferenciar vozes simuladas de vozes autênticas por meio da análise de espectrogramas e de ferramentas de inteligência artificial, como a ElevenLabs. Por meio da criação de scripts para a avaliação de padrões espectrais e aplicação de métodos de Deep Learning e Machine Learning, conseguimos distinguir diferenças significativas entre as frequências de vozes reais e as vozes sintetizadas.

Os achados indicam que a aplicação de espectrogramas e a identificação de atributos como o HOG (Histogram of Oriented Gradients) são eficientes na distinção de vozes. A matriz de confusão e as métricas de categorização demonstram a exatidão e consistência do modelo, alcançando 100% de precisão ao reconhecer as categorias "Clonada" e "Original". Estes resultados sugerem que técnicas de avaliação de frequência e padrões vocais podem proporcionar um nível extra de proteção contra fraudes e manipulações por DeepFakes de áudio.

Este estudo evidencia que análises computacionais de espectrogramas podem ser recursos úteis na identificação de vozes falsas. Em um contexto em que a tecnologia DeepFakes é cada vez mais empregada em situações problemáticas, como fraudes, é crucial criar técnicas eficientes para identificar tais manipulações, a fim de salvaguardar a integridade das informações e a segurança da população.

## REFERÊNCIAS

Almutairi, Z., & Elgibreen, H. (2022). A Review of Modern Audio Deepfake Detection Methods: Challenges and Future Directions. *Algorithms*, 15(5), 155. Acesso em: 17/04/2024. Disponível em: <https://doi.org/10.3390/a15050155>.

Alves Priscila. *Inteligência e Redes Neurais*, IPEA, 2020. Acesso em 21/04/2024. Disponível em : [Inteligência Artificial e Redes Neurais - Centro de Pesquisa em Ciência, Tecnologia e Sociedade \(ipea.gov.br\)](https://www.ipea.gov.br)

Fanaya, Patrícia Fonseca. Deepfake e a realidade sintetizada. *TECCOGS – Revista digital de tecnologias cognitivas*, n.23, jan./jun.2021, p. (104-118). Acessado em: 21/04/2024. Disponível em: [Vista do Deepfake e a realidade sintetizada \(pucsp.br\)](https://www.pucsp.br)

IBM Brasil. O que é Deep Learning? Acesso em: 20/04/2024, Disponível em: <https://www.ibm.com/br-pt/topics/deep-learning>

CNN. Saiba o que é deepfake, técnica de inteligência artificial que foi apropriada para produzir desinformação. Acesso em: 02/06/2024. Disponível em <https://www.cnnbrasil.com.br/noticias/saiba-o-que-e-deepfake-tecnica-de-inteligencia-artificial-que-foi-apropriada-para-produzir-desinformacao/>

ComunitIA. ElevenLabs. Acesso em: 02/06/2024. Disponível em: <https://www.comunitia.com/ferramenta/eleven-labs>

Convertio. Conversor de áudio. Acesso em: 03/06/2024. Disponível em: ConverterMP3 em WAV (Online e Gratuito) — Convertio

IElevenLabs. ElevenLabs. Acessado em: 02/06/2024. Disponível em: AI VoiceGenerator & Text to Speech | ElevenLabs

Kaspersky daily. Não acredite em tudo o que ouve: deepfakes de voz (2023). Acesso em: 23/04/2024. Disponível em: Não acredite em tudo o que ouve: deepfakes de voz ([kaspersky.com.br](https://www.kaspersky.com.br)).

Masood, M., Nawaz., Malik, K.M., Ali, J. & Irtaza A. (2021) Deepfakes Generation and Detection: State-of-the-art, open challenges, countermeasures, and way forward. Cornell University. Acessado em: 23/04/2024. Disponível em: [2103.00484.pdf \(arxiv.org\)](https://arxiv.org/abs/2103.00484)

Nishida, M. Silvia., Weber, Silke. Anna. Theresa., Oliveira, Felipe Augusto K de. & Troll Juliana. *Voz Humana*. Nadi. Acesso em: 23/04/2024. Disponível em [Nossa Missão \(unesp.br\)](https://www.unesp.br).

Ponti, M., & Costa, G. (2017). Como funciona a Deep Learning (p. 63-93). ISBN978-85-7669-400-7. Acesso em 21/04/2024. Disponível em: [Ponti\\_Costa\\_Como-funciona-o-Deep-Learning\\_2017.pdf \(usp.br\)](https://www.usp.br)

Sichman, Jaime. *Inteligência Artificial e sociedade: Avanços e Riscos*. Scielo Brasil, 35, p. (37-49), 2021. Acesso em: 20/04/2024. Disponível em: [SciELO - Brasil - Inteligência Artificial e sociedade: avanços e riscos Inteligência Artificial e sociedade: avanços e riscos](https://www.scielo.br).

Spencer, Michael K., tradução: Gabriela Leite (2019). DeepFake, a mais recente ameaça distópica. OutrasPalavras. Acessado em: 21/04/2024. Disponível em: DeepFake, a mais recente ameaça distópica - Outras Palavras

UOL Notícias. Deepfake: uso de inteligência artificial em eleições na Argentina enos Estados Unidos. Acesso em: 21/04/2024. Disponível em: <https://noticias.uol.com.br/confere/ultimas-noticias/2024/03/03/deepfake-uso-inteligencia-artificial-eleicoes-argentina-estados-unidos.htm>

Your Physicist, 4 tipos mais comuns de técnicas de análise espectral. Acessado em: 23/04/2024. Disponível em: 4 tipos mais comuns de técnicas de análise espectral (your-physicist.com)