

FILTRAGEM DE SINAIS SOBRE GRAFOS APLICADA À CLASSIFICAÇÃO DE DADOS RUIDOSOS DEFINIDOS EM ESTRUTURAS IRREGULARES

SIGNAL FILTERING OVER GRAPHS APPLIED TO THE CLASSIFICATION OF NOISY DATA IN IRREGULAR STRUCTURES

Jorge Barros Medeiros¹
Felipe Alberto Barbosa Simão Ferreira²

RESUMO

As redes convolucionais baseadas em grafos (*Graph Convolutional Networks*, GCN) permitem que modelos de redes neurais profundas aprendam a partir de dados definidos em estruturas irregulares representados por meio de um grafo. Essa abordagem tem atraído cada vez mais atenção nos últimos anos. Tais algoritmos geralmente aprendem com base na informação associada aos vértices e arestas do grafo, sendo possível utilizá-las para melhorar o desempenho de diversas tarefas como classificação de vértices, de um sinal definido sobre o grafo ou do próprio grafo. O objetivo deste trabalho é avaliar a classificação de dados ruidosos dispostos em uma estrutura irregular a partir do treinamento de filtros passa-baixas realizado pelas camadas convolucionais de uma GCN. Os filtros são projetados e aplicados baseando-se em ferramentas de processamento de sinais sobre grafos como a transformada de Fourier sobre grafos. A rede neural convolucional baseada em grafos realizará o aprendizado de parâmetros para diferentes escalas de ruídos no domínio da transformada de Fourier sobre grafos que sejam capazes de extrair informação relevante para classificação do conjunto de dados ruidosos.

Palavras-chave: processamento digital de sinais; aprendizado de máquina; aprendizagem profunda; redes neurais baseadas em grafos.

ABSTRACT

Graph convolutional networks (GCN) allow deep neural networks to learn from data defined in irregular structures represented by a graph. This approach has attracted more and more attention in recent years. Such algorithms generally learn based on the information associated with the vertices and edges present in the graph, being possible to use them to improve the performance of several tasks such as classification of vertices, a signal defined on the graph or the graph itself. The objective of this work is to evaluate the classification of noisy data arranged in an irregular structure from the training of low-pass filters performed by the convolutional layers of a GNN. Filters are designed and applied based on signal processing tools on graphs such as the graph Fourier transform. The graph-based convolutional neural network will perform the learning of parameters for different noise scales in the graph Fourier transform domain that are able to extract relevant information for classification of the noisy dataset.

¹ Bacharelado em Engenharia Eletrônica na Universidade Federal Rural de Pernambuco – Unidade Cabo de Santo Agostinho, 2022

² Doutor em Engenharia Elétrica na Universidade Federal de Pernambuco, Unidade Cabo de Santo Agostinho, 2022

Keywords: digital signal processing, machine learning, deep learning, graph neural networks.

INTRODUÇÃO

O processamento de sinais multidimensionais faz referência às ferramentas para tratamento e análise de sinais cuja representação adequada requer o uso de mais de uma dimensão¹. O exemplo mais corriqueiro de tal processamento é o de imagens bidimensionais, que encontra aplicação em vários cenários como compressão, cifragem e marca d'água digital². O processamento de vídeo e o de imagens tridimensionais (imagens médicas provenientes de ressonância magnética, por exemplo) também se enquadram nesse contexto³.

Outro tipo de sinal multidimensional que tem recebido crescente atenção da Academia e da Indústria é a chamada função plenóptica, que associa a representação da intensidade de luz capturada de qualquer ponto de vista ou posição espacial 3D à direção angular, à cada comprimento de onda e ao longo do tempo⁴. A partir desse modelo surgiram novos tipos de imagens baseadas em representações simplificadas da função plenóptica; dois dos principais exemplos dessas representações são as imagens de *light field*⁵ e as nuvens de pontos⁶.

Considerando sinais que são definidos em estruturas tipicamente regulares, os conceitos de análise no domínio da frequência já são bem definidos e representam um conjunto de ferramentas muito úteis para diversas aplicações. Porém, à medida que se tem uma maior dimensionalidade, tem-se também mais informação a ser processada e as técnicas tradicionais no domínio da transformada passam a capturar menos informação a respeito das componentes de frequência existentes nesses modelos. Além disso, temos também objetos que são tipicamente modelados em estruturas irregulares em que as conexões entre as amostras seguem regras

diversas.

Nesse contexto, uma nova área do processamento digital de sinais vem se estruturando ao longo dos anos, conhecida como Processamento de Sinais sobre Grafos (GSP, do inglês *Graph Signal Processing*). Com esses novos conceitos é possível estender a noção de filtragem linear e invariante ao deslocamento (LSI, do inglês *Linear and Shift Invariant*) e, com isso, definir uma transformada de Fourier sobre grafos (GFT, do inglês *Graph Fourier Transform*)⁷.

A GFT pode ser vista como uma generalização para transformadas discretas ordinárias e dar origem a outros tipos de⁸. em conjunto com a filtragem, ela desempenha um papel importante em várias operações sobre grafos⁹. Como a GFT leva em consideração a própria estrutura irregular do grafo com seus vértices e arestas, esta ferramenta é capaz de representar todas as componentes de frequência de um sinal definido sobre o grafo.

Aliado às técnicas de processamento de sinais estão os procedimentos de aprendizado de máquina que também possuem a função de extrair informação relevante de um conjunto de dados. Diversos modelos de aprendizagem surgiram ao longo dos anos, e recentemente, vêm sendo propostos modelos para dados em grafos como as Redes Convolucionais baseadas em Grafos (*Graph Convolutional Networks, GCN*). A principal diferença desse tipo de rede neural para as redes convencionais é que, em suas camadas convolucionais, a operação de convolução é aplicada no domínio da transformada de Fourier sobre grafos. A operação de convolução é aplicada com filtros que são treinados pelo modelo para extrair características relevantes do grafo¹⁰.

Os métodos de aprendizado de

grafos mapeiam os recursos de um grafo para vetores de recursos com as mesmas dimensões na incorporação espaço.

Um modelo ou algoritmo de aprendizado de grafo converte diretamente os dados na saída sem projetar o grafo em um espaço de baixa dimensão. A maioria dos métodos de aprendizado de grafos são baseados ou generalizados a partir de técnicas de *Deep Learning*, porque conseguem codificar e representar dados de gráfico em vetores. A saída vetores de aprendizagem de grafos estão em espaço contínuo. O objetivo do aprendizado de grafos é extrair as características desejadas de um grafo. Assim, sua representação pode ser facilmente utilizada por tarefas de classificação de nó sem um processo de incorporação explícito¹¹.

O principal objetivo deste trabalho é utilizar filtros passa-baixas treinados por uma GCN para classificar sinais ruidosos definidos em estruturas irregulares e modelados sobre grafos. Será avaliada uma rede neural convolucional baseada em grafos com o objetivo de realizar o aprendizado de parâmetros para diferentes escalas de ruídos no domínio da transformada de Fourier sobre grafos que sejam capazes de extrair informação relevante para classificação de um conjunto de dados.

Além de proporcionar uma análise vértice frequência mais precisa, as ferramentas de GSP (*Graph Signal Processing*) também proporcionaram a criação de novos modelos de redes neurais baseados nas estruturas de um grafo. Com esses modelos é possível atuar em tarefas de classificação para dados definidos em estruturas irregulares, como nuvens de pontos em sistemas de veículos autônomos, redes sociais, ligações proteína-proteína, entre outros.

Uma das aplicações mais recentes foi a de classificação de COVID-19 a partir de radiografias torácicas. Para isso, (Saha et

al., 2021)¹² fez uso de imagens que foram modeladas como grafos aplicando um algoritmo de *Graph Isomorphism Network*. Já (Morales et al., 2020) modelou dados genômicos como grafos para classificação, aplicando uma rede neural convolucional obtendo uma acurácia de aproximadamente 83%¹³.

As redes neurais convolucionais baseadas em grafos, por exemplo, utilizam a definição de convolução de um sinal sobre um grafo para extrair características de interesse e aumentar consideravelmente a acurácia das classificações. Nesse contexto, fica evidente o potencial das ferramentas de GSP e a literatura carece de trabalhos que analisam outras ferramentas que possam auxiliar técnicas de aprendizado de máquina para grafos.

METODOLOGIA

Neste plano de trabalho será estudada e avaliada a Transformada de Fourier sobre Grafos (GFT, do inglês *Graph Fourier Transform*) para aplicação de filtros passa baixas com objetivo de auxiliar técnicas de aprendizado de máquina na atividade de classificação de sinais sobre grafos. Será considerada a abordagem, proposta por Shuman e colaboradores, originada da teoria espectral de grafos que é restrita a grafos não direcionados (cenário ao qual se encontra grande parte dos problemas reais). Nesse contexto, a matriz Laplaciana pode ser vista como um operador diferença atuando em um sinal amostrado sobre um grafo e através de sua diagonalização pode-se, por exemplo, definir a GFT.

A primeira etapa do trabalho consiste em implementar uma rede neural baseada em grafos para resolver problemas de classificação com dados modelados em estruturas deste tipo. A rede neural implementada é a do tipo convolucional que estende os conceitos de convolução do processamento de sinais clássicos para a

convolução de um sinal sobre um grafo. A operação de convolução é utilizada principalmente para extrair características relevantes do sinal sobre o grafo. Esta abordagem já é amplamente utilizada para classificação de imagens e recentemente foi estendida para utilização com grafos.

Desta forma, em vez de avaliarmos a rede neural convolucional com imagens convencionais, as imagens serão convertidas na forma de sinais amostrados sobre grafos e a operação de convolução da rede neural será realizada no domínio da transformada de Fourier sobre grafos. A rede neural será responsável por treinar os parâmetros para um conjunto de filtros passa-baixas que serão utilizados para extrair características relevantes do sinal que ajudem na classificação.

O objetivo é treinar a rede neural convolucional com um conjunto de treinamento sem modificações (isto é, sinais sem ruído), em seguida inserir ruído no conjunto de teste e avaliar o desempenho dos filtros passa-baixas aprendidos pela rede neural com esses dados ruidosos. A expectativa é que se tenha uma ferramenta que permita classificar sinais sobre grafos mesmo quando eles apresentam algum tipo de interferência ruidosa.

Base de Dados


Para a aplicação do método, foi selecionada uma base de dados contendo imagens de dígitos manuscritos de 0 a 9, podendo ser visualizada na Figura 1. Esta base é conhecida pelo nome de MNIST e é bastante utilizada para avaliação de técnicas para reconhecimento automático de manuscrito (Figura 1).

Tais imagens são definidas como matrizes, sendo, portanto, necessário realizar a transformação para o formato de grafo. Na Figura 2 é apresentado o modelo de um grafo em *grid* que possa ser utilizado como estrutura de suporte para os pixels das

imagens. Essas imagens são formadas por uma matriz 28x28, ou seja, 784 pixels. A transformação para o formato de grafo. Na Figura 2 é apresentado o modelo de um grafo em *grid* que possa ser utilizado como estrutura de suporte para os pixels das imagens. Essas imagens são formadas por uma matriz 28x28, ou seja, 784 pixels. Na Figura 2 é apresentado o modelo de um grafo em *grid* que possa ser utilizado como estrutura de suporte para os pixels das imagens.

Essas imagens são formadas por uma matriz 28x28, ou seja, 784 pixels. a transformação para o formato de grafo. Na Figura 2 é apresentado o modelo de um grafo em *grid* que possa ser utilizado como estrutura de suporte para os pixels das imagens. Essas imagens são formadas por uma matriz 28x28, ou seja, 784 pixels.

Figura 1 – Exemplos de imagens com números manuscritos da base MNIST.

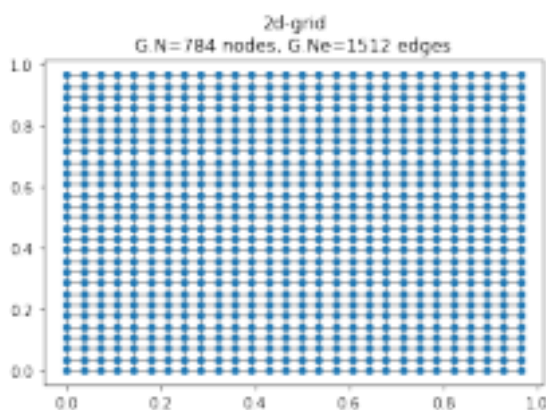


Fonte: Autor, 2022

Portanto o grafo também deve ter essa mesma estrutura, isto é, 784 vértices (cada vértice representa um pixel), e os vértices vizinhos (nas laterais, acima e abaixo) são conectados com arestas. A base MNIST possui um conjunto de treinamento de 60.000 exemplos e um conjunto de teste de 10.000 exemplos. É um subconjunto do NIST *Special Database 3* (dígitos escritos por funcionários do *United States Census Bureau*) e *Special Database 1* (dígitos escritos por estudantes do ensino médio) que contêm imagens monocromáticas de dígitos

manuscritos. Os dígitos foram normalizados em tamanho e centralizados em uma imagem de tamanho fixo. As imagens originais em preto branco (de dois níveis) do NIST foram normalizadas em tamanho para conter uma caixa de 20x20 pixels, preservando sua proporção. As imagens resultantes contêm níveis de cinza como resultado da técnica de *anti-aliasing* usada pelo algoritmo de normalização. Por fim, as imagens foram centralizadas em uma imagem 28x28 pelo cálculo do centro de massa dos pixels.

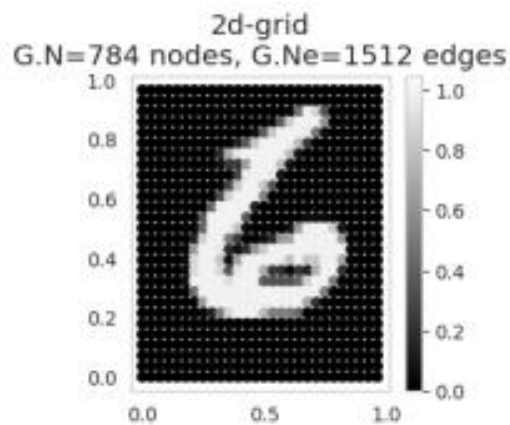
Figura 2 – Exemplo de um grafo em *grid* com 784 vértices que simulam uma matriz 28x28.



Fonte: Autor, 2022

É importante mencionar que existem ainda outras possibilidades de como esse grafo poderia ser definido, tanto com relação a quantidade de pontos quanto à forma em que os vértices são conectados, porém, este trabalho irá se limitar a analisar os resultados conforme a estrutura apresentada na Figura 2. Na Figura 3 é apresentada uma das imagens com o valor da intensidade de cinza dos pixels sendo tomados como sinal definido sobre a estrutura do grafo.


Figura 3 – Imagem da base MNIST definida sobre um grafo



Fonte: Autor, 2022

Podemos verificar os coeficientes da GFT do sinal sobre o grafo conforme apresentado na Figura 4. É possível notar que como o sinal apresenta descontinuidades em diversos pontos (entre a definição do número e o plano de fundo da imagem), o espectro de frequência apresenta componentes de magnitude diferente de zero por todo eixo de frequência. No entanto, a maior parte da energia ainda se encontra concentrada no que seriam as frequências baixas, isto é, próximas à origem, sendo a frequência harmônica sua principal componente. Isso é uma característica importante pois nos permite utilizar uma ferramenta de filtragem como forma de atenuar um possível ruído utilizando filtros passa baixas e aumentar o desempenho de um classificador do tipo de uma rede neural convolucional baseada em grafos.


Figura 4 – Coeficientes da GFT do sinal sobre o grafo.



Fonte: Autor, 2022


Para realização de uma análise inicial, a partir do sinal definido, foi realizada a inserção de um ruído aleatório de distribuição normal com média 0 e variância igual a um percentual da amplitude máxima do sinal. Como forma de exemplificar, após a aplicação de um ruído com variância de 40% da amplitude máxima do sinal original, podemos visualizar o grafo na Figura 5. Note que agora existe uma maior variação nas regiões que predominavam pixels pretos ou brancos. Isso indica uma maior prevalência de componentes de alta frequência. Pode-se visualizar os coeficientes da GFT na Figura 6.

Figura 5 – Imagem da base MNIST definida sobre um grafo com o ruído inserido.



Fonte: Autor, 2022

Figura 6 – Coeficientes da GFT do sinal sobre o grafo com ruído.




Fonte: Autor, 2022

A Figura 7 apresenta o sinal filtrado após um filtro passa-baixas ideal em que

foram mantidos apenas os 200 primeiros coeficientes. Neste ponto está sendo referido como um filtro passa-baixas ideal pois o decaimento entre a banda de passagem e a banda de rejeição do filtro é feito de forma abrupta. O filtro está sendo implementado programaticamente escolhendo uma faixa contínua de coeficientes que serão mantidas e zerando o restante dos coeficientes.

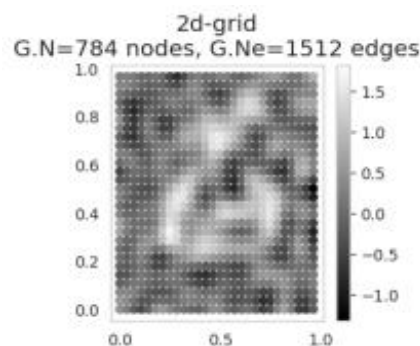
Figura 7 – Coeficientes da GFT do sinal sobre o grafo após filtragem.



Fonte: Autor, 2022

A partir da aplicação da filtragem espectral, é possível realizar a recuperação parcial da imagem. Na Figura 8 é identificado uma menor concentração de sinais de alta frequência, permitindo uma maior distinção entre a estrutura do grafo e o dígito.

Figura 8 – Imagem da base MNIST após aplicação de filtro passa-baixa.




Fonte: Autor, 2022

Tal filtragem irá auxiliar a reconstruir o sinal após a inserção de um ruído. Para fins de simulação, neste

trabalho está sendo considerado um ruído gaussiano branco aditivo de média nula e variância igual a um percentual da amplitude máxima do sinal original. Na Figura 9 é apresentada a distribuição do ruído para diferentes percentuais considerados na variância

Figura 9 – Distribuição variando a amplitude.



Fonte: Autor, 2022

Treinamento dos Modelos de Classificação

A partir do sinal original sem ruído, foi implementado uma rede neural convolucional cuja sua forma construtiva contém filtros compartilhados em todo local do grafo. A estrutura da rede neural foi definida com duas camadas convolucionais de 32 nós de saída e a função de ativação utilizada foi a ReLU (*Rectified Linear Unit*). Essas camadas são responsáveis por realizar o treinamento dos filtros passa-baixas de modo a extrair as características mais relevantes dos grafos para sua classificação. Foi inserido um processo de *Flattening* fornecendo a rede neural um tensor 2D como entrada, tendo como principal funcionalidade unidimensionalizar o sinal a ser classificado. Por fim, a estrutura da rede é composta por duas camadas densas, a primeira possui 512 nós (foi usada a função de ativação ReLU) e a seguinte possui 10 nós (a função de ativação utilizada foi a *softmax*). As camadas densas são

responsáveis por utilizar as características extraídas das camadas convolucionais (por meio dos filtros treinados) para realizar a classificação final dos dados. Portanto, a rede neural convolucional sobre grafo age como um banco de filtros passa-baixas, permitindo realizar a recuperação do sinal.

Como forma de avaliação, foi utilizado a métrica acurácia, indicando o quão assertivo o algoritmo é quando submetido à inclusão de ruídos em seus respectivos sinais. Foram realizados testes variando a amplitude do ruído, entre 10% e 70%, indicando faixas de alterações no sinal de que a rede neural consegue ter uma performance significativa.

A fim de mostrar o fluxo de desenvolvimento do presente trabalho, pode-se visualizar na Figura 10 todas as etapas.

Figura 10 – Fluxograma de desenvolvimento.



Fonte: Autor, 2022

RESULTADOS E DISCUSSÃO

Nesta seção são apresentados os resultados obtidos durante a etapa de classificação, indicando a acurácia obtida. A partir da metodologia proposta, foi possível realizar a classificação do sinal como um modelo preditivo, aplicando os conceitos de inteligência artificial e aprendizado de máquina através de uma rede neural convolucional baseada em grafos.

Conforme visualizado na Tabela 1,

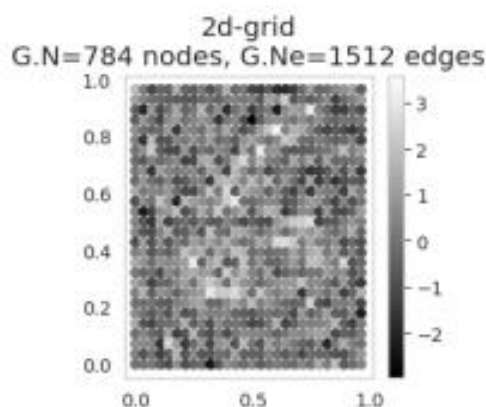
podemos encontrar o desempenho da rede neural quando submetido a diferentes percentuais de ruídos. É possível notar que mesmo com altos níveis de ruído ao sinal original, a rede construída consegue obter resultados de classificação relativamente altos. Por exemplo, é possível perceber que mesmo com um ruído de variância igual a 70% de amplitude do sinal original o sinal apresentado no grafo está altamente degradado. À olho nu quase não é possível perceber qual é o número apresentado na imagem, conforme é possível visualizar na Figura 11. Porém, mesmo assim a rede neural consegue obter taxas de acerto próximas a 80%.

Tabela 1 – Resultados de acurácia da rede neural convolucional construída avaliada com conjuntos de teste submetidos a diferentes níveis de ruído.

Percentual do ruído	Acurácia
10%	97,76%
20%	97,52%
30%	96,35%
40%	94,35%
50%	90,45%
60%	85,37%
70%	79,17%

Fonte: O Autor, 2022

Figura 11 – Imagem definida sobre o grafo com um ruído de 70%.



Fonte: Autor, 2022

CONCLUSÕES E PERSPECTIVAS

Neste trabalho foram aplicadas técnicas de processamento digital de sinais sobre grafos, bem como conceitos relacionados a área de aprendizado de máquina. Utilizou-se de uma base de dados contendo 70.000 imagens de dígitos manuscritos variando de 0 a 9, sendo 60.000 para treinamento e 10.000 para validação do aprendizado. A base de dados possui uma estrutura de matriz, contendo pixels variando entre 0 e 255, sendo necessário realizar a transformação para o formato de Grafo. A partir da estrutura criada, foi aplicada a transformada de Fourier sobre grafos para analisar a concentração de energia contida nas imagens. Em um primeiro momento, foi construída uma rede neural convolucional contendo filtros compartilhados em todo local do grafo com duas camadas convolucionais de 32 nós de saída. Tais filtros considerados passa-baixas foram utilizados para filtragem espectral de ruídos pouco representativos nas imagens.

Em um segundo momento, foi inserido um ruído gaussiano branco aditivo de média zero e variância igual a um percentual da amplitude máxima do sinal original. Tal alteração permitiu que ao aplicar a transformada de Fourier sobre grafos, houvesse uma maior concentração de energia em frequências consideradas mais altas. Portanto, a imagem degradada foi útil para que fosse aplicada a rede neural previamente treinada a fim de mesmo com o sinal ruidosos, realizar a filtragem espectral e identificar a imagem. Tal rede neural obteve desempenho próximo ou superior a 80%, mesmo altamente degradada.

Como trabalhos futuros, pretende-se avaliar outras bases de dados para a mesma metodologia, podendo replicar os conceitos aqui desenvolvidos para outras aplicações, bem como detecção de anomalias em redes de sensores e *smart grids*, por exemplo. Devido ao problema ter sido aplicado em uma estrutura de grafo, é

possível ter maior flexibilidade nos problemas.

REFERÊNCIAS

¹ SMIRNOV, Alexandre. **Processing of multidimensional signals**. Berlin, Springer Science & Business Media, 2013. *Ebook*. Disponível em: <https://link.springer.com/book/10.1007/978-3-662-03855-0>. Acesso em: 18 dez. 2023.

² GONZALEZ, Rafael; WOODS, Richard. **Digital image processing**. England, Pearson Education Limited, 2018. *Ebook*. Disponível em: <https://dl.icdst.org/pdfs/files4/01c56e081202b62bd7d3b4f8545775fb.pdf>. Acesso em: 18 dez. 2023.

³ SEMMLOW, John. **Biosignal and medical image processing**. Boca Raton, CRC Press. 2008. *Ebook*. Disponível em <https://doi.org/10.1201/9780203024058>. Acesso em 18 dez. 2023.

⁴ ADELSON, Edward; BERGEN, James. The plenoptic function and the elements of early vision. **Computational models of visual processing**. Cambridge, v. 1, n. 2, p. 3-20, 1991. Disponível em: https://vision.csee.wvu.edu/classes/cs674-f17/reading/ThePlenopticFunction_1991.pdf. Acesso em: 18 de dez. 2023.

⁵ JOLFAEI, Alireza; WU, Xin-Wen; MUTHUKKUMARASAMY, Vallipuram. A 3D object encryption scheme which maintains dimensional and spatial stability. **IEEE transactions on information forensics and security** v. 10, n. 2, p. 409-422, fev. 2015. Disponível em: <https://iee-ac.org/docs/Alireza.pdf>. Acesso em 18 dez. 2023.

⁶ WEINMANN, M. **Reconstruction and analysis of 3D scenes: From Irregularly Distributed 3D Points to Object Classes**. Switzerland.

Springer, 2016. *Ebook*. Disponível em: <https://doi.org/10.1007/978-3-319-29246-5>. Acesso em 18 dez. 2023.

⁷ SANDRYHAILA, Aliaksei; MOURA, José. Discrete signal processing on graphs. **IEEE Transactions on Signal Processing**, v. 61, n. 7, p. 1644-1656, dez. 2012. DOI: <https://doi.org/10.1109/TSP.2013.2238935>. Disponível em: <https://arxiv.org/pdf/1210.4752.pdf>. Acesso em: 18 de dez. 2023.

⁸ FRACASTORO, Giulia; FOSSON, Sophie; MAGLI, Enrico. Steerable discrete cosine transform. **IEEE Transactions on Image Processing**, v. 26, n. 1, p. 303-314, dez. 2018. DOI: <https://doi.org/10.1109/TIP.2016.2623489>. Disponível em: <https://arxiv.org/pdf/1610.09152.pdf>. Acesso em 18 dez. 2023.

⁹ CHEN, Siheng; TIAN, Dong; FENG, Chen; VETRO, Anthony; KOVACEVIC, Jelena. Fast resampling of three-dimensional point clouds via graphs. **IEEE Transactions on Signal Processing**, v. 66, n. 3, p. 666-682, fev. 2017. DOI: [10.1109/TSP.2017.2771730](https://doi.org/10.1109/TSP.2017.2771730). Disponível em: <https://arxiv.org/pdf/1702.06397.pdf>. Acesso em 18 dez. 2023.

¹⁰ FRIGO, Oriel; BROSSARD, Rémy; DEHAENE, David. Graph Context Encoder: Graph Feature Inpainting for Graph Generation and Self-supervised Pretraining. **arXiv**, v. 1, jun. 2021. DOI: <https://doi.org/10.48550/arXiv.2106.10124>. Disponível em: <https://arxiv.org/pdf/2106.10124.pdf>. Acesso em 18 dez. 2023.

¹¹ XIA, Feng; SUN, Ke; YU, Shuo; AZIZ, Abdul; WAN, Liangtian; PAN, Shirui; LIU, Huan. Graph learning: A survey. **IEEE Transactions on Artificial Intelligence**, v. 2, n. 2, p. 109-127, abr. 2021. DOI: [10.1109/TAI.2021.3076021](https://doi.org/10.1109/TAI.2021.3076021).

Disponível em:
<https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=9416834>. Acesso em 18 dez. 2023.

¹² SAHA, Pritam; MUKHERJEE, Debadyuti; SINGH, Pawan Kumar; AHMADAN, Ali; FERRARA, Massimiliano; SARKAR, Ram. Retracted article: Graphcovidnet: A graph neural network based model for detecting COVID-19 from ct scans and x-rays of chest. **Scientific reports**, v. 11, n. 1, p. 8304, nov. 2021. Disponível em: <https://www.nature.com/articles/s41598-021-87523-1>. Acesso em: 18 dez. 2023,

¹³ MORALES, J. Alejandro; SALDAÑA, Román; CASTOLO, Manuel H. Santana; CERNA, Carlos E. Torres; BORRAYO, Ernesto; RUIZ, Adriana P. Mendizabal; PÉREZ, Hugo A. Vélez; RUIZ, Gerardo Mendizabal. Deep learning for the classification of genomic signals. **Mathematical Problems in Engineering**, mai. 2020. Disponível em: <https://doi.org/10.1155/2020/7698590>. Acesso em 18 dez. 2023.

¹⁴ WELLING, Max; KIPF, Thomas. Semi-supervised classification with graph convolutional networks. **ArXiv**, v. 1, fev. 2017. DOI: <https://doi.org/10.48550/arXiv.1609.02907>. Disponível em: <https://arxiv.org/pdf/1609.02907.pdf>. Acesso em 18 dez. 2023.