

Seleção de Fatias Guiada por Grad-CAM em Tomografia Computadorizada para Detecção de Hemorragias Cerebrais

Daniel C Santos¹, Paulo H N Gonçalves¹, Eduardo Souto¹, Robson L O Amorim²

¹Instituto de computação – Universidade Federal do Amazonas (UFAM)

²Faculdade de Medicina – UFAM

Av. Gen. Rodrigo Octavio 6200, Coroad I – 69080-900 – Manaus – AM – Brasil

{daniel.santos,paulo,esouto}@icomp.ufam.edu.br, amorim.robson@gmail.com

Abstract. *Intracranial hemorrhages are severe and potentially fatal conditions that require rapid and accurate diagnosis to reduce neurological sequelae and mortality. Computed tomography (CT) is widely used for this detection, but manual evaluation is time-consuming and subject to interobserver variability. Three-dimensional convolutional neural networks (CNN3D) have been applied to assist in volumetric medical image analysis. However, their use is hindered by high computational cost and redundant information in full CT volumes. This study proposes Gradient-weighted Class Activation Mapping (Grad-CAM) 2D Guided Selection (SGG-2D), a hybrid approach that combines adaptive and non-adaptive techniques for efficient slice selection. The method employs a 2D classification model with Grad-CAM to identify the most informative slices, complemented by a structured sampling strategy that ensures a balanced distribution of selected slices across the tomographic volume. The approach was compared against six existing methods, achieving the highest accuracy (75.67%) and AUC-ROC (82.72%). The results demonstrate that optimized slice selection not only reduces computational complexity but also enhances the quality of data input for CNN3Ds, leading to improved accuracy in anomaly classification in volumetric exams.*

Resumo. *As hemorragias intracranianas são condições graves e potencialmente fatais, exigindo um diagnóstico rápido e preciso para reduzir sequelas neurológicas e mortalidade. A tomografia computadorizada (TC) é amplamente utilizada nesse contexto, mas a avaliação manual é demorada e sujeita a variações interobservador. Redes Neurais Convolucionais Tridimensionais (CNN3D) têm sido aplicadas para auxiliar na análise de imagens médicas volumétricas, porém sua utilização enfrenta desafios como alto custo computacional e redundância de informações nos volumes completos de TC. Este estudo propõe o método Seleção Guiada por Mapeamento de Ativação de Classe Ponderado por Gradiente (Grad-CAM) 2D (SGG-2D), uma abordagem híbrida que combina técnicas adaptativas e não adaptativas para seleção eficiente de fatias. A estratégia emprega um modelo de classificação 2D associado ao Grad-CAM para identificar fatias mais informativas, complementado por um esquema de amostragem estruturada que garante uma distribuição equilibrada das fatias ao longo do volume tomográfico. A abordagem foi comparada com seis métodos existentes, alcançando a maior acurácia (75,67%) e AUC-ROC (82,72%). Os*

resultados demonstram que a seleção otimizada de fatias não apenas reduz a complexidade computacional, mas também aprimora a qualidade dos dados de entrada para CNN3Ds, resultando em maior precisão na classificação de anomalias em exames volumétricos.

1. Introdução

As hemorragias intracranianas são condições médicas graves que exigem um diagnóstico rápido e preciso para reduzir sequelas neurológicas e a mortalidade [Anouk Stein et al. 2019]. A tomografia computadorizada (TC) é amplamente utilizada para esse tipo de detecção, fornecendo uma análise detalhada das estruturas cerebrais [Zunair et al. 2020]. No entanto, a avaliação manual dessas imagens é um processo demorado, sujeita a variabilidade interobservadores e propensa a erros, devido à grande quantidade de fatias geradas em um exame.

Com o avanço das redes neurais profundas, modelos computacionais foram propostos para auxiliar na análise de imagens médicas volumétricas. Redes neurais convolucionais 3D (CNN3D) têm-se mostrado eficazes para esse tipo de tarefa, mas sua aplicação enfrenta desafios, como o alto custo computacional e a redundância de informações nos volumes completos de TC [Oladimeji et al. 2023].

Para mitigar esse problema, uma estratégia amplamente explorada é a seleção de fatias, na qual apenas as regiões mais relevantes do volume são analisadas. Esse processo reduz a carga computacional, ao mesmo tempo em que preserva informações críticas para o diagnóstico [da Silva 2023]. Diferentes abordagens para essa seleção foram desenvolvidas e podem ser classificadas em dois grupos principais: métodos não adaptativos e métodos adaptativos.

Os métodos não adaptativos, como *Subset Slice Selection* (SSS) [Zunair et al. 2019], *Even Slice Selection* (ESS) e *Spline Interpolated Zoom* (SIZ), utilizam regras fixas para a seleção de fatias, sem considerar a distribuição da informação ao longo do volume [Zunair et al. 2020]. Embora sejam computacionalmente eficientes, esses métodos podem descartar informações relevantes ou incluir fatias redundantes. Por outro lado, os métodos adaptativos utilizam características estatísticas e estruturais das imagens para selecionar automaticamente as fatias mais informativas. Entre esses, estão as técnicas como *Variance Values* (VV), *Entropy Values* (EV) e *Gradient Magnitude* (GM), que analisam variações de intensidade, textura e gradientes para priorizar as fatias com maior relevância clínica [Oladimeji et al. 2023]. Apesar de mais sofisticados, esses métodos dependem de ajustes finos de parâmetros e selecionam fatias com base apenas em estatísticas de intensidade, textura ou gradiente, sem fornecer uma justificativa visual clara sobre sua relevância clínica. Isso pode limitar a transparência do processo de seleção para médicos e especialistas.

Recentemente, métodos adaptativos baseados em aprendizado de máquina e explicação de modelos têm sido explorados para a seleção de fatias. O *Grad-CAM Slice Selection* (GSS), por exemplo, utiliza uma CNN3D e Grad-CAM para identificar automaticamente fatias relevantes para a decisão do modelo [da Silva 2023]. Embora essa abordagem preserve as regiões mais informativas, sua dependência de uma CNN3D aumenta a carga computacional e pode comprometer a escalabilidade do método.

Neste estudo, propomos um método híbrido denominado Seleção Guiada por Grad-CAM 2D (SGG-2D), que combina técnicas adaptativas e não adaptativas para otimizar a seleção de fatias em tomografias computadorizadas. Primeiramente, utilizamos uma rede neural convolucional profunda 2D (CNN2D) associada ao Grad-CAM para identificar e ranquear as fatias mais informativas com base nas ativações internas do modelo, permitindo uma seleção mais interpretável e orientada à predição. Em seguida, incorporamos uma estratégia inspirada na técnica SSS, dividindo a tomografia em regiões distintas para garantir uma distribuição equilibrada das fatias ao longo do volume. Nossa abordagem visa combinar o melhor dos dois mundos, integrando a interpretação visual proporcionada pelo Grad-CAM com a eficiência da CNN2D, garantindo uma seleção de fatias mais equilibrada e informativa. Além disso, ao utilizar uma CNN2D em vez de uma CNN3D para essa etapa, reduzimos significativamente o custo computacional do processo, tornando a abordagem mais viável para aplicações práticas sem comprometer a precisão diagnóstica.

As principais contribuições deste trabalho são:

- Nova abordagem para seleção de fatias: Proposta do SGG-2D, que combina *Grad-CAM* com um modelo CNN2D, tornando a seleção de fatias mais eficiente e interpretável.
- Combinação de técnicas adaptativas e não adaptativas: Integração de um modelo de classificação com *Grad-CAM* e um método de amostragem estruturada para garantir uma distribuição equilibrada das fatias.
- Avaliação quantitativa abrangente: Comparativo do SGG-2D com seis métodos existentes, demonstrando ganhos em acurácia, revocação e AUC-ROC.

O artigo está dividido da seguinte forma: A Seção 2 apresenta os trabalhos relacionados, discutindo diferentes estratégias para a seleção de fatias em tomografias. A Seção 3 descreve a metodologia utilizada e os modelos de avaliação. A Seção 4 detalha os experimentos realizados e discute os resultados obtidos. Por fim, a Seção 5 traz as conclusões e direções para trabalhos futuros.

2. Trabalhos Relacionados

Nesta seção, são apresentados estudos que abordam o problema da seleção de fatias em exames médicos, utilizando abordagens não adaptativas e adaptativas. Enquanto os métodos não adaptativos utilizam regras fixas para a seleção de fatias, independentemente das características do volume analisado, os métodos adaptativos ajustam a escolha com base em atributos específicos, como variação de intensidade ou gradiente.

2.1. Métodos Não Adaptativos

As abordagens não adaptativas foram exploradas inicialmente na literatura devido à sua simplicidade e eficiência computacional. O método *Subset Slice Selection* (SSS) foi proposto como uma estratégia inicial para a amostragem de fatias em tomografias computadorizadas por [Zunair et al. 2019]. Posteriormente, essa abordagem foi aprimorada com o desenvolvimento do *Even Slice Selection* (ESS) e do *Spline Interpolated Zoom* (SIZ), visando reduzir limitações da seleção fixa de fatias e melhorar a representatividade dos volumes analisados [Zunair et al. 2020].

Essas técnicas foram amplamente exploradas na literatura e são descritas a seguir, destacando suas características e limitações.

O *Subset Slice Selection* (SSS) seleciona fatias fixas em três posições predefinidas: início, meio e fim do exame. Essa abordagem simplifica o processamento, mas pode não capturar toda a variabilidade anatômica, comprometendo a representatividade das informações [Zunair et al. 2019].

Para lidar com essa limitação, Zunair et al. propuseram o *Even Slice Selection* (ESS), uma versão aprimorada do SSS que distribui uniformemente as fatias ao longo do volume, utilizando um fator de espaçamento. Essa abordagem permite uma melhor preservação da estrutura volumétrica e uma representação mais fiel do volume analisado [Zunair et al. 2020].

O *Spline Interpolated Zoom* (SIZ) foi introduzido para superar ainda mais as limitações da amostragem fixa, eliminando a necessidade de selecionar fatias específicas. Em vez disso, o volume é interpolado ao longo do eixo Z usando *spline interpolation*, permitindo uma representação contínua da estrutura volumétrica sem perda significativa de informações anatômicas. Essa técnica mantém um nível maior de integridade do volume em comparação com SSS e ESS, sendo particularmente útil para aplicações de redes neurais convolucionais 3D [Zunair et al. 2020].

2.2. Métodos Adaptativos

Embora os métodos não adaptativos ofereçam simplicidade e eficiência computacional, sua natureza fixa pode resultar na seleção de fatias pouco informativas ou redundantes. Para superar essas limitações, métodos adaptativos foram propostos, ajustando a seleção de fatias conforme a variação de intensidade, gradiente ou relevância clínica. Essas técnicas permitem uma seleção mais direcionada, aumentando a representatividade das fatias escolhidas e preservando informações críticas para o diagnóstico.

Variance Values (VV), *Entropy Values* (EV) e *Gradient Magnitude* (GM) foram propostos por [Oladimeji et al. 2023] como métodos adaptativos para identificar as fatias mais informativas em tomografias computadorizadas. O VV mede a dispersão das intensidades de pixel em cada fatia, destacando regiões anatômicas complexas. O EV quantifica a diversidade textural das imagens, enquanto o GM identifica mudanças abruptas de contraste, destacando bordas e contornos anatômicos relevantes.

Para melhorar a continuidade estrutural das fatias selecionadas, [Oladimeji et al. 2023] propuseram a inclusão de fatias vizinhas, garantindo transições anatômicas preservadas e mantendo a coerência volumétrica dos exames. Estudos demonstraram que a combinação de EV e GM melhora a precisão dos modelos de aprendizado profundo, equilibrando informação clínica e eficiência computacional.

O *Grad-CAM Slice Selection* (GSS), apresentado por [da Silva 2023], utiliza mapeamento de ativação ponderado por gradientes. Diferentemente das demais técnicas, o GSS aproveita as ativações internas de CNN3Ds para identificar automaticamente as regiões de interesse em cada fatia, com base na sua relevância para a decisão do modelo. Essa abordagem preserva as fatias mais informativas e elimina as redundantes, otimizando a complexidade computacional enquanto mantém a continuidade estrutural das imagens. Os resultados obtidos por esse método demonstram que o GSS supera tanto métodos adaptativos quanto não adaptativos em termos de *AUC* e *F1-Score*, sendo particularmente eficaz na detecção de anomalias clínicas complexas.

Diferentemente das abordagens discutidas nesta seção, o presente estudo propõe uma estratégia híbrida que combina Grad-CAM com um modelo de classificação 2D para a seleção adaptativa de fatias. Enquanto abordagens anteriores que utilizam Grad-CAM são baseadas em CNN3D, a técnica aqui desenvolvida aplica o método de visualização baseado em gradientes diretamente sobre uma CNN2D, permitindo identificar fatias relevantes sem a necessidade de processar volumes inteiros em alta dimensionalidade. Essa modificação reduz significativamente o custo computacional, tornando a abordagem mais eficiente e escalável.

Além disso, o método proposto integra a interpretação visual do Grad-CAM com uma estratégia de amostragem estruturada, garantindo uma distribuição equilibrada das fatias selecionadas ao longo do volume. Esse aspecto não é explorado pelas abordagens existentes, que frequentemente selecionam fatias com base apenas em estatísticas globais ou em critérios isolados de relevância.

3. Método

Esta seção descreve o método proposto para a seleção automática de fatias em tomografias computadorizadas, detalhando suas principais etapas. A abordagem utiliza um modelo de classificação 2D para processar as fatias individualmente e emprega Grad-CAM para interpretar as predições e atribuir uma pontuação de relevância a cada imagem. A Figura 1 apresenta uma visão geral desse processo, ilustrando como o Grad-CAM contribui para a definição da importância de cada fatia dentro do volume analisado.

A partir dessas pontuações, é realizada a seleção final das fatias que comporão o conjunto reduzido, garantindo que a amostra final preserve as informações mais relevantes para a análise. Esse processo considera uma distribuição equilibrada das fatias ao longo do volume, conforme detalhado na Figura 2.

As próximas seções fornecem uma descrição de cada uma dessas etapas, incluindo a seleção das fatias 2D com Grad-CAM, o treinamento do modelo de classificação, a geração de mapas de calor e o critério utilizado para a escolha das fatias mais representativas.

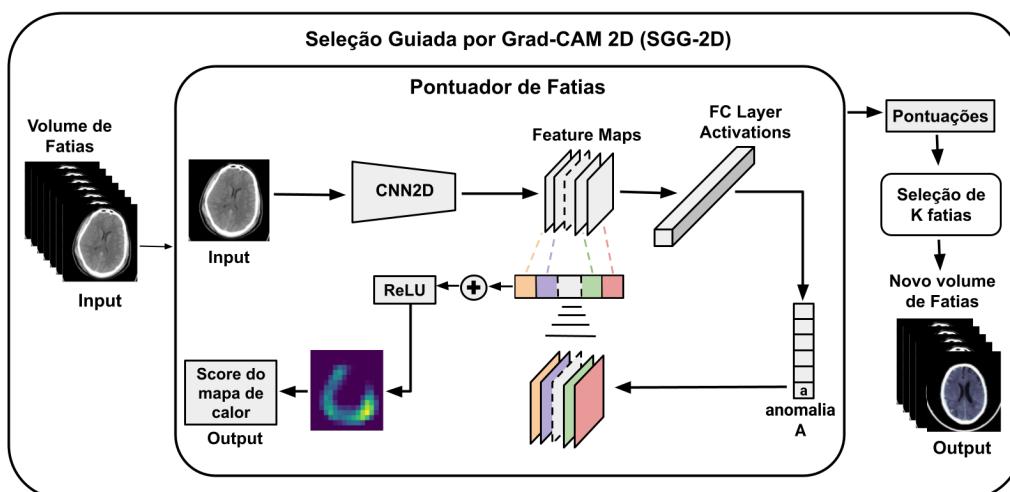


Figura 1. Método de Seleção Guiada por Grad-CAM 2D (SGG-2D).

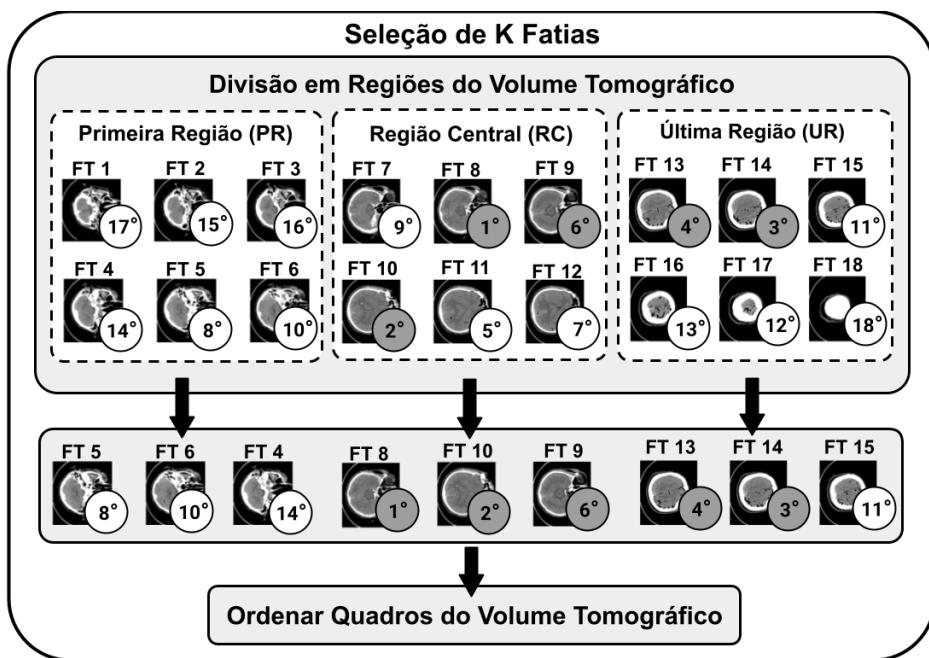


Figura 2. Método de Seleção de K Fatias.

3.1. Seleção Guiada por Grad-CAM 2D

O método proposto utiliza um modelo de classificação 2D treinado para identificar anomalias em tomografias computadorizadas, empregando Grad-CAM para interpretar as decisões do modelo e atribuir um grau de relevância a cada fatia. Esse processo permite selecionar automaticamente as imagens mais informativas, reduzindo o número de fatias a serem analisadas sem comprometer a qualidade diagnóstica.

Inicialmente, cada tomografia computadorizada é decomposta em suas fatias individuais, que são processadas pelo modelo de classificação 2D. Este foi treinado para prever a probabilidade de presença de diferentes tipos de hemorragia intracraniana. Para cada fatia, o Grad-CAM é aplicado sobre a última camada convolucional do modelo, gerando o mapa de calor que destaca as regiões mais relevantes para a predição, como ilustrado na subárea da Figura 1, denominada Pontuador de Fatias.

A intensidade das ativações no mapa de calor é convertida em uma pontuação de relevância, calculada pela soma das ativações normalizadas nas regiões destacadas. Fatias com pontuações mais altas indicam maior presença de padrões característicos da classe predita. Essas pontuações servem como critério para a seleção final, que ocorre dentro de três regiões do volume tomográfico: primeira região (PR), região central (RC) e última região (UR). Essa divisão, inspirada no *Subset Slice Selection* (SSS), garante uma distribuição equilibrada das fatias selecionadas, assegurando que todas as partes do volume contribuam para a análise final e reduzindo possíveis vieses na seleção.

Dentro de cada uma das três regiões, a seleção segue uma ordem específica, garantindo que a mesma quantidade de fatias seja escolhida em cada uma. Primeiramente, são priorizadas as fatias identificadas como anômalas pelo modelo classificador. Dentro desse grupo, a seleção é realizada com base na pontuação obtida na etapa anterior, priorizando as fatias com pontuações mais altas dentro de sua respectiva região. Na Figura 2,

essas fatias anômalas são representadas por círculos cinza, acompanhados da respectiva colocação.

Caso o número de fatias anômalas disponíveis em uma região seja menor do que o necessário para completar a seleção, as fatias normais mais relevantes serão utilizadas. Assim como no caso das fatias anômalas, a escolha dessas fatias normais também segue um critério de pontuação, priorizando aquelas com maior relevância dentro da região. Essas fatias normais são representadas na Figura 2 por bolinhas brancas, acompanhadas de sua colocação.

Dessa forma, garantimos que todas as regiões da tomografia tenham um número equilibrado de fatias selecionadas, preservando a estrutura volumétrica original e evitando vieses que poderiam comprometer o desempenho do modelo no reconhecimento de padrões anômalos. Além disso, essa estratégia impede que exames com poucas fatias anômalas sejam descartados, permitindo uma análise mais abrangente dos dados disponíveis.

3.1.1. Modelo de Classificação 2D

Para a tarefa de classificação, foi empregada a arquitetura ResNeXt-101 32x8d, um modelo baseado em blocos residuais agregados, proposto por [Xie et al. 2017]. A arquitetura consiste em blocos convolucionais com conexões residuais, nos quais cada bloco convolucional contém camadas de convolução 2D, seguidas por *batch normalization* e pela função de ativação *Rectified Linear Activation Function* (ReLU). Para evitar sobreajuste, foi aplicado *dropout* de 20% antes da camada de saída.

Optamos por uma abordagem multiclasse, permitindo que uma mesma fatia seja rotulada com múltiplos tipos de hemorragia intracraniana. Essa estratégia amplia a sensibilidade do modelo, facilitando a identificação simultânea de diferentes condições patológicas. Além disso, o uso de um modelo multiclasse melhora a interpretabilidade dos mapas de calor gerados pelo Grad-CAM, pois permite que a rede destaque regiões específicas associadas a cada uma das classes preditas, enriquecendo o processo de seleção das fatias mais relevantes.

O treinamento foi realizado sobre um subconjunto dos dados da Radiological Society of North America (RSNA) Intracranial Hemorrhage Detection [Anouk Stein et al. 2019], contendo imagens de tomografias computadorizadas rotuladas para diferentes tipos de hemorragia intracraniana, como epidural, intraparenquimatosa, intraventricular, subaracnoidea e subdural, além de uma classe de fatias normais. Com base nas configurações adotadas por [Burduja et al. 2020], seguimos a mesma metodologia para a definição dos hiperparâmetros do nosso modelo. Assim, utilizamos a função de perda logarítmica para múltiplos rótulos (*multi-label log loss*), somando a entropia cruzada binária para cada classe de hemorragia. O otimizador *Adam* foi empregado, com uma taxa de aprendizado inicial de 0,0001, reduzida para 0,00002 na terceira época. O modelo foi treinado por 3 épocas, com um *batch size* de 32. Além disso, técnicas de *data augmentation* foram aplicadas, incluindo rotação, espelhamento, deslocamento, escaleonamento e ajuste de brilho, aumentando a diversidade do conjunto de treinamento e melhorando a generalização do modelo.

4. Experimentos e Resultados

Para validar a eficácia do método proposto, foram conduzidos experimentos comparando sua abordagem com outras técnicas de seleção de fatias em tomografias computadorizadas. Nesta seção, são descritos o conjunto de dados utilizado, a metodologia de avaliação, as métricas empregadas e os resultados obtidos, destacando as principais vantagens e limitações do modelo proposto.

4.1. Base de Dados

Tabela 1. Distribuição do conjunto de dados utilizado nos experimentos.

Partição do Conjunto	Número de Tomografias	Número de Fatias
Treinamento do modelo de classificação 2D	21.000	728.513
Avaliação dos métodos de seleção	744	24.290
Total	21.744	752.803

O conjunto de dados utilizado foi disponibilizado pela RSNA, composto por mais de 752.000 imagens tomográficas (DICOM) de crânio, com dimensões de 512×512 pixels. Para cada tomografia, formada pelas fatias da coleção de dados, foi aplicada uma classificação binária, distinguindo entre exames com a presença ou ausência de anomalias. Essa base foi originalmente disponibilizada na competição RSNA Intracranial Hemorrhage Detection, no Kaggle [Anouk Stein et al. 2019].

O conjunto foi particionado conforme apresentado na Tabela 1, seguindo a abordagem utilizada por [Burduja et al. 2020]. Para evitar viés, foi garantido que fatias e tomografias do mesmo paciente não estivessem simultaneamente nos conjuntos de treinamento e avaliação. Além disso, foi mantido um equilíbrio entre os diferentes subtipos de hemorragia, assegurando uma distribuição proporcional das classes.

4.2. Avaliação da Seleção de Fatias

A eficácia do método SGG-2D foi avaliada utilizando uma abordagem baseada em aprendizado profundo. Idealmente, a seleção de fatias poderia ser validada por especialistas clínicos, que analisariam a relevância das imagens escolhidas. No entanto, essa alternativa não estava disponível para este estudo. Como solução, foi empregada uma rede neural convolucional 3D (CNN3D) para avaliar se o conjunto reduzido de fatias preserva informações suficientes para um diagnóstico preciso.

Para essa etapa, foi utilizada a arquitetura ResNeXt-101 3D, projetada para capturar informações espaço-temporais em volumes de imagens médicas [Köpüklü et al. 2019]. O modelo recebe como entrada o volume reduzido gerado pelo processo de seleção e realiza a classificação final entre exames normais e anômalos. A Figura 3 ilustra o processo de avaliação, no qual cada método de seleção de fatias é aplicado a um conjunto de tomografias e gera um volume reduzido, que posteriormente é classificado por uma CNN3D para determinar a presença ou ausência de anomalias.

Nos experimentos conduzidos, cada exame foi representado por um subconjunto de 15 fatias, seguindo a recomendação de [Bai et al. 2024]. Esse estudo demonstrou que o uso de um número fixo de fatias mantém as principais informações diagnósticas, ao mesmo tempo que reduz a redundância de imagens e o custo computacional. Essa escolha foi validada empiricamente, garantindo um equilíbrio entre a qualidade da entrada e o desempenho computacional do modelo 3D.

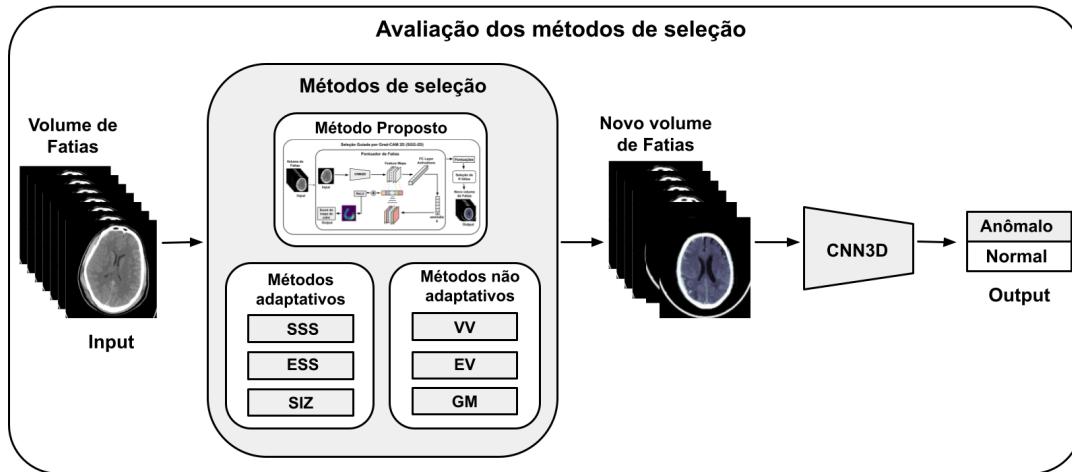


Figura 3. Método de avaliação das técnicas de seleção.

4.2.1. Modelo de Classificação 3D

A rede ResNeXt-101 3D foi treinada para classificar exames com e sem anomalias utilizando o conjunto de dados descrito na Seção 4.1. O treinamento foi realizado sobre o conjunto de dados RSNA, garantindo um balanceamento adequado das classes para mitigar o problema de desbalanceamento. Como função de perda, utilizou-se a *Cross-Entropy Loss* ponderada, ajustando os pesos conforme a distribuição das classes. O modelo foi otimizado utilizando o algoritmo *Adam*, com uma taxa de aprendizado inicial de 0,001, reduzida dinamicamente por meio da estratégia *StepLR*. O treinamento foi conduzido por um total de 100 épocas, empregando um *batch size* de 16 amostras por iteração.

Para melhorar a generalização do modelo e evitar sobreajuste, foram aplicadas estratégias de regularização, incluindo um fator de *weight decay* de 0,001 e um *momentum* de 0,936. Além disso, técnicas de *data augmentation* foram incorporadas durante o treinamento, incluindo operações como rotação, espelhamento e ajustes de contraste. Adicionalmente, foi utilizada uma estratégia de *warmup* durante as primeiras 5 épocas, para um ajuste mais estável dos parâmetros iniciais.

Ao final do treinamento, o modelo foi avaliado no conjunto de teste utilizando as métricas descritas na próxima seção, garantindo uma avaliação quantitativa da eficácia da seleção de fatias.

4.3. Métricas de Avaliação

A eficácia do método SGG-2D foi avaliada utilizando métricas padrão de classificação, incluindo acurácia, precisão, revocação (sensibilidade), *F1-score* e *AUC-ROC* (Área Sob a Curva da Característica de Operação do Receptor). A acurácia indica a proporção de classificações corretas; a precisão mede a proporção de exames anômalos corretamente identificados, sendo importante para evitar falsos positivos; e a revocação, a proporção de anomalias detectadas, essencial para reduzir falsos negativos. O *F1-score* representa a média harmônica entre precisão e revocação, equilibrando os dois tipos de erro.

A curva *ROC* (Receiver Operating Characteristic) e sua área (*AUC-ROC*) avaliam

a capacidade do modelo de distinguir entre exames normais e anômalos. Valores de *AUC* próximos de 1 indicam excelente separação entre as classes, enquanto valores próximos de 0,5 indicam um modelo sem capacidade discriminativa. A utilização dessas métricas permite avaliar o impacto da seleção de fatias na qualidade do modelo 3D, garantindo que as informações essenciais para a classificação sejam preservadas.

4.4. Resultados e Discussão

Nesta seção, são apresentados os resultados quantitativos obtidos a partir dos experimentos, destacando a influência da seleção de fatias no desempenho dos modelos. A Tabela 2 compara o método SGG-2D com abordagens adaptativas e não adaptativas, enquanto a Figura 4 ilustra o desempenho dos modelos por meio da curva *ROC*.

Tabela 2. Tabela de métricas comparando diferentes técnicas de seleção.

Métricas \ Técnicas de Seleção	SGG-2D	SSS	ESS	SIZ	VV	EV	GM
Acurácia	0.7567	0.7477	0.6936	0.6936	0.7387	0.7477	0.7387
Precisão	0.7551	0.8000	0.6800	0.7142	0.7948	0.7400	0.8108
Revocação	0.7115	0.6153	0.6538	0.5769	0.5961	0.7115	0.5769
F1-Score	0.7326	0.6956	0.6666	0.6382	0.6813	0.7254	0.6741
AUC-ROC	0.8272	0.8106	0.7229	0.7881	0.7969	0.7946	0.8142

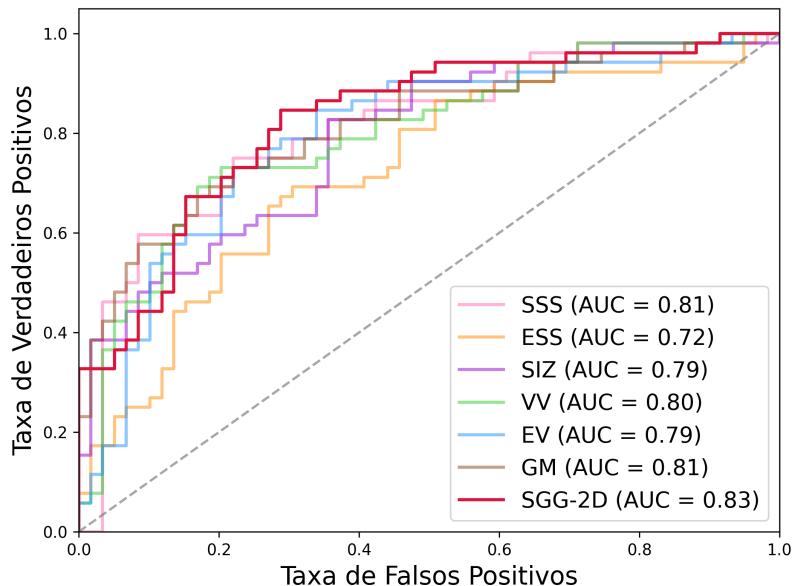


Figura 4. Curvas ROC para os diferentes métodos de seleção de fatias. A área sob a curva (*AUC*) é indicada para cada método, sendo que o método proposto (SGG-2D) obteve o maior valor (0.83), demonstrando melhor capacidade discriminativa entre exames normais e anômalos.

A Tabela 2 mostra que o método SGG-2D obteve a maior acurácia (0,7567), superando todas as demais técnicas avaliadas. Esse resultado indica que a seleção guiada por Grad-CAM 2D permite preservar informações relevantes para a classificação, reduzindo a redundância de fatias sem comprometer a qualidade do diagnóstico.

Em relação à precisão, os métodos SSS e GM apresentaram valores ligeiramente superiores (0,8000 e 0,8108, respectivamente). No entanto, esses métodos tiveram uma revocação inferior (0,6153 e 0,5769), sugerindo que, embora evitem falsos positivos, podem deixar de identificar casos positivos, reduzindo a sensibilidade do modelo. Já o método SGG-2D obteve um melhor equilíbrio entre precisão e revocação, refletido pelo maior *F1-score* (0,7326), o que sugere uma melhor capacidade de generalização.

Por outro lado, a técnica ESS apresentou os piores resultados, com acurácia de 0,6936 e *AUC-ROC* de 0,7229. Esse desempenho inferior pode estar associado à sua abordagem de amostragem uniforme, que não considera a relevância informativa das fatias selecionadas. Da mesma forma, o método SIZ, que realiza interpolação volumétrica, mostrou desempenho inferior ao SGG-2D, reforçando a hipótese de que a manipulação da estrutura volumétrica pode levar à perda de informações essenciais para a classificação.

A Figura 4 apresenta a curva *ROC* para cada um dos métodos. O valor *AUC-ROC* do SGG-2D (0,8272) foi o maior entre os avaliados, indicando que essa abordagem possui melhor capacidade discriminativa entre exames normais e anômalos. Esse resultado sugere que a seleção de fatias informativas não apenas reduz a complexidade computacional, mas também melhora a qualidade da entrada de dados, contribuindo para um melhor desempenho da CNN3D.

Esses achados demonstram o potencial do método SGG-2D para aplicações em diagnóstico assistido por imagem, indicando que sua estratégia híbrida pode ser uma solução promissora para otimizar a análise de tomografias computadorizadas e aprimorar a detecção de hemorragias intracranianas.

5. Conclusão

Este trabalho apresentou o método SGG-2D, uma abordagem híbrida para a seleção de fatias em tomografias computadorizadas que combina a interpretabilidade do Grad-CAM com a eficiência computacional de um modelo de classificação 2D. O objetivo foi otimizar a entrada de redes neurais convolucionais volumétricas, reduzindo a complexidade computacional sem comprometer a qualidade da informação utilizada na análise de hemorragias intracranianas.

A avaliação experimental demonstrou que o SGG-2D superou métodos adaptativos e não adaptativos, alcançando maior acurácia e *AUC-ROC*. A seleção orientada por Grad-CAM garantiu uma escolha mais informativa das fatias, equilibrando precisão e revocação. Em contrapartida, abordagens não adaptativas, como SSS e ESS, apresentaram limitações na retenção de características discriminantes, enquanto métodos adaptativos baseados em estatísticas estruturais tiveram desempenhos intermediários.

Os resultados sugerem que a seleção otimizada de fatias pode contribuir para a redução da carga computacional e potencialmente beneficiar a capacidade de redes neurais 3D na identificação de anomalias em exames volumétricos. Isso abre caminho para o uso do SGG-2D em aplicações médicas assistidas por inteligência artificial, especialmente em cenários onde a eficiência computacional é um fator crítico.

Como direções futuras, pretende-se explorar variantes do SGG-2D, incorporando arquiteturas híbridas 2D-3D para otimizar ainda mais a representatividade dos dados. Além disso, técnicas de explicabilidade mais avançadas, como *Grad-CAM++* e *SHAP*,

serão investigadas para aprofundar a compreensão das decisões do modelo. Outro eixo de estudo será a adaptação do método para diferentes modalidades de exames médicos e patologias, ampliando seu impacto na prática clínica.

6. Agradecimentos

O presente trabalho é resultado do projeto de Pesquisa e Desenvolvimento (P&D) 001/2020, firmado com a Universidade Federal do Amazonas e a FAEPI, Brasil, que conta com financiamento da Samsung, utilizando recursos da Lei de Informática para a Amazônia Ocidental (Lei Federal nº 8.387/1991), e sua divulgação está de acordo com o artigo 39 do Decreto nº 10.521/2020. Este trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES-PROEX) – Código de Financiamento 001. Adicionalmente, este trabalho foi parcialmente financiado pela Fundação de Amparo à Pesquisa do Estado do Amazonas – FAPEAM – por meio do projeto PDPG.

Referências

- Anouk Stein, M., Wu, C., Carr, C., Shih, G., Kalpathy-Cramer, J., Elliott, J., kalpathy, Prevedello, L., Marc Kohli, M., Lungren, M., Culliton, P., Ball, R., and MD, S. H. (2019). Rsna intracranial hemorrhage detection. <https://kaggle.com/competitions/rsna-intracranial-hemorrhage-detection>. Kaggle.
- Bai, Q., Gao, Y., Chen, F., Zhang, Y., Yang, Y., Zhong, L., Yang, W., and Yang, Y. (2024). Representative slice selection and multi-view projection learning for pulmonary tuberculosis infectiousness identification using ct volume. *IEEE Access*, 12:1374–1390.
- Burdaja, M., Ionescu, R. T., and Verga, N. (2020). Accurate and efficient intracranial hemorrhage detection and subtype classification in 3d ct scans with convolutional and long short-term memory neural networks. *Sensors*, 20(19):5611.
- da Silva, L. A. (2023). Abordagem de aprendizado profundo para extração de quadros significativos em volumes de tomografia computadorizada. Dissertação de mestrado, Universidade Federal do Amazonas - ICOMP-UFAM, Manaus, Brasil.
- Köpüklü, O., Kose, N., Gunduz, A., and Rigoll, G. (2019). Resource efficient 3d convolutional neural networks. *arXiv preprint arXiv:1904.02422*.
- Oladimeji, O., Ayaz, H., Unnikrishnan, S., and McLoughlin, I. (2023). Lightweight deep learning for breast cancer diagnosis based on slice selection techniques. In *Proceedings of the 2023 Irish Conference on Artificial Intelligence and Cognitive Science (AICS)*. IEEE.
- Xie, S., Girshick, R., Dollár, P., Tu, Z., and He, K. (2017). Aggregated residual transformations for deep neural networks. *arXiv preprint arXiv:1611.05431*.
- Zunair, H., Rahman, A., Mohammed, N., and Cohen, J. P. (2019). Estimating severity from ct scans of tuberculosis patients using 3d convolutional nets and slice selection. *CLEF2019 Working Notes*.
- Zunair, H., Rahman, A., Mohammed, N., and Cohen, J. P. (2020). Uniformizing techniques to process ct scans with 3d cnns for tuberculosis prediction. In Maglogiannis, I., Iliadis, L., and Pimenidis, E., editors, *Predictive Intelligence in Medicine*, pages 156–168. Springer International Publishing.