

Redes Neurais Convolucionais para Estimação de Sinais em Calorímetros de Altas Energias

Diogo Alves Cardinot, Bernardo Sotto-Maior Peralva, Gustavo Barbosa Libotte e Luciano Manhães de Andrade Filho

Resumo—Aceleradores de partículas são instalações complexas que promovem colisões em altíssimas energias, visando à descoberta de nova física, validação de modelos fundamentais da física e aumento da precisão das medidas. Nesse contexto, sistemas de calorimetria desempenham papel fundamental ao fornecer informações acerca da energia das partículas, essencial para potenciais descobertas. Este trabalho avalia o desempenho do método tipicamente empregado, conhecido como do Filtro Ótimo (OF) e de arquiteturas de Redes Neurais Convolucionais (CNN) na reconstrução da amplitude e fase de sinais simulados que representam pulsos de resposta de calorímetros. A comparação é realizada por métricas quantitativas, e os resultados indicam um desempenho superior das CNNs em condições de operação em alto empilhamento de sinais esperadas em colidores modernos.

Palavras-Chave—Calorímetros de altas energias, simulação de dados, estimação de sinais, filtro ótimo, convolutional neural network.

Abstract—Particle accelerators are complex facilities that enable collisions at extremely high energies, aiming at the discovery of new physics, the validation of fundamental physics models, and improved measurement precision. In this context, calorimeter systems play a fundamental role by providing information about particles, which is essential for potential discoveries. This work evaluates the performance of the Optimal Filter (OF) method and Convolutional Neural Network (CNN) architectures in reconstructing the amplitude and phase of simulated signals that represent calorimeter response pulses. The comparison is performed using quantitative metrics, and the results indicate improved performance of CNNs under severe high occupancy conditions.

Keywords—High-energy calorimeters, data simulation, signal estimation, optimal filter, convolutional neural network.

I. INTRODUÇÃO

Na física de altas energias, a estimação de parâmetros desempenha papel fundamental na análise de fenômenos de colisões de partículas, constituindo a base para a reconstrução de grandezas físicas e para a operação eficiente de sistemas de *trigger* sob altas taxas de eventos. Esses procedimentos permitem identificar sinais relevantes em meio ao grande volume de dados de aceleradores modernos, conforme discutido em obras clássicas sobre eletrônica rápida e detecção em física de partículas [1–3]. Essa capacidade de reconstrução precisa é

essencial tanto para a busca por novas partículas quanto para a validação de modelos fundamentais da física.

Os calorímetros desempenham papel central nesse processo. Em experimentos de grande porte, são sistemas de detecção altamente segmentados, projetados para medir a energia depositada por partículas via cascatas eletromagnéticas ou hadrônicas, desenvolvidas em camadas alternadas de materiais ativos e absorvedores [4]. Esses detectores fornecem respostas rápidas e perfis detalhados de deposição de energia, permitindo medições de alta resolução em energia e posição, além de suportar sistemas de *trigger* online [1, 5–7].

A forma como os sinais dos calorímetros são amostrados depende do tipo de detector, do regime de operação e das propriedades das partículas incidentes. Consequentemente, métodos robustos de filtragem digital tornam-se indispensáveis para mitigar ruído eletrônico, flutuações intrínsecas dos materiais e efeitos não lineares, garantindo a reconstrução fiel dos parâmetros físicos de cada evento. Em experimentos atuais, as taxas elevadas de dados exigem técnicas capazes de discriminar sinal e ruído quase em tempo real. Nesse contexto, abordagens clássicas de processamento e métodos modernos de aprendizado profundo têm sido cada vez mais explorados para otimizar a reconstrução de energia em calorímetros [8, 9].

Nesse contexto, o presente trabalho compara o desempenho do Filtro Ótimo (OF), amplamente utilizado em calorimetria de altas energias [10, 11], e de redes neurais convolucionais (CNNs) aplicadas à estimação de amplitude e fase do sinal em um canal de leitura de calorímetro. Para isso, utilizam-se dados simulados pela biblioteca Pulse Generator [12], que reproduz formas de pulso características de calorímetros em física de altas energias. Consideram-se apenas pulsos unipolares, como os do TileCal [11]. Em princípio, a extensão a pulsos bipolares, como os de calorímetros de argônio líquido (LAr) [10], também é viável, já que tanto o OF quanto as CNNs se adaptam ao pulso de referência, bastando retrainar os modelos sobre dados desse regime.

II. CALORÍMETROS DE ALTAS ENERGIAS

Em experimentos de física de altas energias, os calorímetros são responsáveis por medir e absorver praticamente toda energia das partículas produzidas nas colisões [4]. Isso os torna componentes centrais dos detectores modernos, pois permitem a medição tanto de partículas carregadas quanto neutras (como fótons e nêutrons), possibilitando a reconstrução de mésons neutros, a determinação da energia transversal faltante e a identificação de estados físicos relevantes [13].

Uma característica fundamental desses sistemas é a sua segmentação (granularidade). Muitos calorímetros empregam uma

Diogo Alves Cardinot, Programa de Pós-Graduação em Modelagem Computacional, IPRJ/UERJ, Nova Friburgo-RJ, e-mail: diogo.cardinot@iprj.uerj.br; Bernardo Sotto-Maior Peralva, Programa de Pós-Graduação em Modelagem Computacional, IPRJ/UERJ, Nova Friburgo-RJ, e-mail: bernardo.peralva@uerj.br; Gustavo Barbosa Libotte, Programa de Pós-Graduação em Modelagem Computacional, IPRJ/UERJ, Nova Friburgo-RJ, e-mail: gustavolibotte@iprj.uerj.br; Luciano Manhães de Andrade Filho, Programa de Pós-Graduação em Engenharia Elétrica, UFJF, Juiz de Fora-MG, e-mail: luciano.andrade@ufjf.edu.br.

estrutura multicamadas altamente segmentada que combina absorvedores e camadas ativas, cada uma equipada com eletrônica de leitura independente. Essa segmentação transversal e longitudinal fornece perfis detalhados de deposição de energia, essenciais para a reconstrução de trajetórias, identificação de partículas e calibração de energia [1].

A granularidade do detector afeta diretamente a taxa de ocupação das células do calorímetro e a complexidade da reconstrução do sinal em cada canal de leitura. Em ambientes de alta luminosidade, o grande número de colisões simultâneas aumenta a probabilidade de sobreposição de sinais (*pile-up*) em múltiplas células. Quanto maior a segmentação, mais delicado se torna o tratamento desses efeitos, exigindo técnicas capazes de lidar com ruído eletrônico, *cross-talk*, saturação e variações de resposta entre células [15].

Outro aspecto essencial é o tempo de resposta do calorímetro. A resolução temporal é crítica para mitigar efeitos de *pile-up* e viabilizar *trigger* em tempo real, já que atrasos na determinação do tempo do sinal podem levar à sobreposição de pulsos de interações subsequentes. Assim, calorímetros rápidos são indispensáveis em experimentos com altas taxas de eventos [16]. Também, calorímetros altamente segmentados são usados em detectores futuros, permitindo algoritmos baseados em *particle flow*, que exploram a granularidade fina para melhorar a resolução em energia de jatos [17].

Para estudar metodologias de reconstrução sem depender de colisões reais, *frameworks* de simulação foram desenvolvidos, como o *Pulse Generator* [12] e o Lorenzetti Showers, sendo este último capaz de simular as seis camadas (três eletromagnéticas e três hadrônicas) para investigar estratégias de reconstrução e algoritmos de *trigger* [14].

III. METODOLOGIA

A. Filtro Ótimo (OF)

O método do Filtro Ótimo permite a reconstrução da amplitude (A) e da fase (τ) de um pulso digital a partir de suas amostras discretas S_i [11], representando a resposta de um canal de leitura de um calorímetro. O sinal medido pode ser descrito como $S_i = Ag(t_i + \tau) + p + n_i$, onde A é a amplitude do pulso, $g(t_i)$ é a amostra de um pulso de referência no instante t_i , τ representa o deslocamento temporal, p é o pedestal e n_i é o ruído eletrônico. Como se espera que o atraso temporal seja pequeno, aplica-se uma expansão em série de Taylor de primeira ordem em $g(t_i + \tau)$, resultando em $S_i = Ag_i + A\tau g'_i + p + n_i$, com $g_i = g(t_i)$ e $g'_i = g'(t_i)$.

A reconstrução da fase é realizada através de um estimador linear, sendo b_i os pesos do OF para a estimação da fase:

$$\hat{\tau}_{OF} = \sum_{i=0}^{N-1} b_i S_i, \quad (1)$$

Para garantir o não enviesamento do estimador, impõe-se $E[\hat{\tau}_{OF}] = \tau$. Assume-se que o ruído segue uma distribuição gaussiana de média nula. Assim, substituindo S_i na Eq. 1:

$$\hat{\tau}_{OF} = A \sum_{i=0}^{N-1} g_i b_i + A\tau \sum_{i=0}^{N-1} g'_i b_i + p \sum_{i=0}^{N-1} b_i \quad (2)$$

Para garantir imunidade a variações de amplitude e pedestal, impõem-se as seguintes restrições:

$$\sum_{i=0}^{N-1} g_i b_i = 0, \quad \sum_{i=0}^{N-1} g'_i b_i = 1 \quad e \quad \sum_{i=0}^{N-1} b_i = 0 \quad (3)$$

Sob essas condições, o estimador se reduz a $\hat{\tau}_{OF} = A\tau$, sendo τ recuperado por normalização pela amplitude do pulso. Os pesos b_i minimizam a variância do estimador, o que equivale a minimizar

$$I_b = \sum_{i,j=0}^{N-1} b_i b_j C_{i,j} + \lambda \left(\sum_{i=0}^{N-1} g_i b_i \right) + \epsilon \left(\sum_{i=0}^{N-1} g'_i b_i \right) + \kappa \left(\sum_{i=0}^{N-1} b_i \right)$$

onde $C_{i,j}$ é a matriz de covariância do ruído, e λ , ϵ e κ são os multiplicadores de Lagrange associados às restrições.

Assim, o sistema linear do OF para reconstrução da fase deve satisfazer as restrições da Eq. 3 e:

$$\sum_{j=0}^{N-1} b_j C_{i,j} + \lambda g_i + \epsilon g'_i + \kappa = 0, \quad \forall i \quad (4)$$

B. Redes Neurais Convolucionais (CNNs)

Para a abordagem baseada em redes neurais, foi empregada uma Rede Neural Convolucional configurada para tarefas de regressão. A entrada do modelo consistiu em uma matriz obtida após a etapa de segmentação, onde cada linha representa um pulso reconstruído a partir das amostras em *free-running*. Cada pulso foi associado ao seu respectivo valor verdadeiro de amplitude, utilizado como alvo no treinamento.

As CNNs constituem uma classe de modelos projetados para processar dados estruturados em grade e, em séries temporais, são adaptadas à sua forma unidimensional (1D-CNN). Sua arquitetura típica é composta por camadas convolucionais, responsáveis pela extração de padrões locais; camadas de *pooling*, que reduzem a dimensionalidade e mitigam o sobreajuste; e camadas densas (*fully connected*), que combinam as características extraídas para produzir a predição final [18].

A principal vantagem das CNNs reside na capacidade de aprender correlações locais na forma do pulso, como bordas de subida, regiões de decaimento e distorções sutis do ruído eletrônico. Essas estruturas são difíceis de modelar explicitamente por métodos lineares, como o OF. Como resultado, a rede atua como um extrator de características treinável, produzindo filtros eficazes para diferentes ocupações e reconstruções de amplitude mais robustas a ruído e distorções de forma [19].

Para garantir estabilidade durante o treinamento e evitar que a rede aprenda uma dependência espúria do pedestal (comprometendo sua generalização a cenários com pedestal distinto ou ausente), o pedestal foi previamente removido. As redes foram treinadas com função de perda MSE, otimizador Adam, *early stopping* e regularização por *dropout*. Esses mecanismos mitigam o sobreajuste e contribuem para a generalização do modelo, avaliada pela validação cruzada com 100 *folds* [18].

Ademais, as CNNs avaliadas apresentam poucos milhares de parâmetros treináveis (cerca de 7,4 mil na CNN-5 e

2,3 mil na CNN-3), ordens de grandeza abaixo de VGG-16 (~138 milhões) ou ResNet-50 (~25 milhões), favorecendo implementação em hardware acelerado (GPUs ou FPGAs) para reconstrução rápida em ambientes de alta taxa de eventos, como os esperados em alta luminosidade. No presente projeto, ambas as metodologias foram executadas em Python (3.9.10): o OF em CPU Ryzen 5 5600X (3.7GHz), e a CNN em GPU GeForce RTX 4070 (12GB VRAM GDDR6X) com TensorFlow (2.10) e CUDA (11.2), em ambiente com 16 GB de RAM (DDR5, 3200MHz).

IV. SIMULAÇÃO DOS DADOS

A. Biblioteca *Pulse Generator*

Como a realização de colisões reais para cada novo estudo é inviável, utilizam-se simuladores capazes de reproduzir os sinais esperados sob diferentes condições experimentais. Um desses simuladores é o *Pulse Generator*, que produz sinais de acordo com parâmetros definidos pelo usuário, fornecendo informações como tempo de amostragem, amplitude verdadeira, amostras do pulso e fase verdadeira [12].

Neste estudo, foram realizadas simulações para gerar 2.000.000 de amostras com amplitudes seguindo distribuição exponencial de média 100 *ADC Counts* (unidade de contagem digital de amplitude do conversor analógico-digital), fase uniformemente distribuída entre -5 e 5 ns (nanossegundos), pedestal constante de 30 *ADC Counts* e parâmetro de deformação de 0,01 *ADC Counts*. Esses parâmetros são típicos de sistemas modernos de calorimetria, já adotados em trabalhos anteriores [20, 21]. O *Pulse Generator* também simula diferentes níveis de ocupação (probabilidade de um canal do calorímetro receber sinais de uma colisão [22]) variando de 0% a 100%, sendo que valores mais elevados correspondem a maior probabilidade de sobreposição de pulsos (*pile-up*). Em ocupação nula, apenas o ruído eletrônico está presente.

Embora dados simulados permitam reprodutibilidade, eles também apresentam limitações: no *Pulse Generator*, os dados representam um único canal do calorímetro, não possibilitando avaliar a reconstrução na geometria completa do detector; além disso, o ruído é modelado como aditivo gaussiano e a forma de pulso é fixa, podendo diferir de condições reais [1, 4].

B. Estratégia de Segmentação dos Dados

Para a aplicação do Filtro Ótimo, os dados devem ser organizados em matrizes com 7 colunas (pulsos com sete amostras temporais) e m linhas. Cada linha corresponde a um pulso completo (resposta do calorímetro a uma colisão), cuja amplitude estimada será comparada ao valor de referência (conhecido pela simulação). No entanto, a biblioteca fornece os sinais em formato *free-running*, ou seja, uma única coluna com r amostras contínuas, sem segmentação entre pulsos. Esse formato exige uma técnica de particionamento para reconstruir a organização matricial necessária ao Filtro Ótimo.

A estratégia adotada, denominada janelamento, reorganiza a série temporal contínua em conjuntos de amostras com sobreposição controlada. No janelamento 7, por exemplo, as sete primeiras amostras formam as colunas da primeira linha da matriz, enquanto a quarta entrada da coluna de amplitude

verdadeira é a referência desse pulso. O conjunto seguinte usa as amostras de índices 2 a 8, com referência na quinta entrada da coluna de amplitude, e assim sucessivamente até processar todos os dados. Esse procedimento garante compatibilidade entre os dados e o modelo do Filtro Ótimo, preservando a coerência temporal dos pulsos simulados. Nessa mesma etapa, o pedestal constante é subtraído de cada amostra, única transformação aplicada aos dados brutos do *Pulse Generator*, que, por serem sintéticos, não apresentam valores ausentes ou *outliers*.

Devido à sobreposição inerente ao janelamento (passo unitário), o particionamento em *folds* foi realizado por embaralhamento aleatório das amostras já segmentadas, sem preservar blocos temporais contíguos (o que pode introduzir alguma correlação entre treino e teste). A mitigação desse efeito, por meio de particionamento em blocos temporais ou por evento de origem, é deixada como trabalho futuro.

V. RESULTADOS E DISCUSSÃO

Para avaliar o desempenho das Redes Neurais Convolucionais em comparação com o método do Filtro Ótimo, múltiplas arquiteturas foram projetadas e avaliadas. Utilizou-se um conjunto padronizado de hiperparâmetros de treinamento, definidos empiricamente, apresentado na Tabela I, garantindo uma comparação justa entre os modelos.

Empregou-se validação cruzada com $k = 100$, acima do convencional (5 ou 10), reservando 1% para teste e 99% para treinamento, dos quais 10% foram usados para validação (*Validation Split*), resultando em 89% treino, 10% validação e 1% teste. O k elevado maximiza a fração de treinamento por partição, relevante dada a distribuição exponencial da amplitude (poucos eventos de alta amplitude), e garante que, ao final das 100 repetições, todas as amostras tenham sido usadas como teste, fornecendo distribuição robusta das métricas entre *folds*. Cada arquitetura foi treinada e avaliada independentemente para os níveis de ocupação considerados (10%, 50%, 80% e 100%).

TABELA I

CONFIGURAÇÕES DE TREINAMENTO DAS ARQUITETURAS DE CNN [23].

PARAM	VAL	DESC
<i>Folds (K-Fold)</i>	100	Validação cruzada
<i>Validation Split</i>	0.1	10% para validação
<i>Batch Size</i>	4096	Amostras por atualização
<i>Epochs</i>	15	Iterações de treinamento
<i>Dropout Rate</i>	30%	Regularização
<i>Optimizer</i>	Adam	Algoritmo de otimização
<i>Loss Function</i>	MSE	Erro Quadrático Médio
<i>Metrics</i>	MAE	Erro Absoluto Médio
<i>Early Stopping</i>	3	Paciência (épocas sem melhoria)

Definiu-se uma arquitetura de referência (CNN-1), não extraída da literatura, mas proposta como configuração simples, da qual as demais variantes foram derivadas por modificações controladas, visando identificar a contribuição individual de cada alteração no resultado final. Cada nova arquitetura incorpora uma modificação específica: mais camadas convolucionais ou densas, variação no número de filtros, alteração no tamanho do *kernel* ou troca da função de ativação [23].

Uma vez que a estimação da fase depende da qualidade da reconstrução da amplitude (conforme $\tau = \frac{\tau_{OF}}{A}$), realizou-se previamente um estudo para identificar as arquiteturas de CNN mais adequadas à estimação de amplitude em diferentes ocupações [23]. Nesse estudo, todas as arquiteturas foram treinadas e avaliadas com quatro métricas: Raiz do Erro Quadrático Médio (RMS), coeficiente de determinação (R^2), Erro Absoluto Médio (MAE) e Erro Absoluto Mediano (MedAE).

A análise revelou que a CNN-5 apresentou o melhor desempenho para 10% e 50% de ocupação, enquanto a CNN-3 foi superior em 80% e 100%, ambas com menores RMS, MAE e MedAE e R^2 mais próximo de 1. A Tabela II apresenta as configurações das melhores arquiteturas e da arquitetura base; a comparação completa entre todas as arquiteturas está em [23].

TABELA II
CONFIGURAÇÕES DAS MELHORES CNNs AVALIADAS [23].

PARAM	Arquitetura		
	CNN-1 (Base)	CNN-3 (Kernel $\uparrow$)	CNN-5 (Densas $\uparrow$)
Cam. Conv.	2	2	2
Filtros	32,16	32,16	32,16
Kernel Size	3,2	5,3	3,2
Ativação	ReLU	ReLU	ReLU
Cam. Densas	1	1	2
Neurônios	32	32	64,32

A Figura 1 ilustra o histograma do erro de estimação de amplitude, evidenciando melhor reconstrução pelas CNNs em relação ao OF, dada sua menor dispersão e médias mais próximas de zero. A Tabela III sumariza a comparação quantitativa dos resultados de amplitude entre as melhores CNNs e o OF, com ganhos significativos em todas as métricas avaliadas.




Fig. 1. Histograma comparativo do erro de estimação da amplitude entre a CNN e o Filtro Ótimo para ocupações (a) 10%, (b) 50%, (c) 80% e (d) 100%.

Com base nas arquiteturas seleccionadas no estudo de amplitude, avaliou-se a reconstrução de fase, contribuição principal deste trabalho. A fase foi estimada combinando a Eq. 1 com as amplitudes reconstruídas, em três cenários: (i) amplitude estimada pelo OF, (ii) amplitude real, e (iii) amplitude estimada pelas CNNs (CNN-5 para 10% e 50%, CNN-3 para 80% e 100%). A Figura 2 apresenta os histogramas do erro de estimação da fase para os quatro níveis de ocupação testados.

TABELA III
COMPARAÇÃO ENTRE O OF E CNN PARA DIFERENTES OCUPAÇÕES.

OCUP	MET	RMS	R^2	MAE	MedAE	Disp. ($\mu \pm \sigma$)
10%	OF	22.8215	0.7239	13.1604	6.2577	20.5271 ± 0.2738
	CNN-5	2.3439	0.9971	0.8608	0.3727	2.3036 ± 0.1574
50%	OF	64.8925	0.4384	51.6169	43.1066	41.3328 ± 0.3430
	CNN-5	13.2832	0.9765	7.3989	2.8654	13.2745 ± 0.1714
80%	OF	93.4024	0.0902	80.7884	73.5991	48.2014 ± 0.3616
	CNN-3	20.8919	0.9545	14.4668	9.6613	20.8929 ± 0.1871
100%	OF	112.0485	-0.2596	100.3583	93.9148	50.6954 ± 0.3324
	CNN-3	24.4371	0.9401	17.7741	12.9849	24.3657 ± 0.2145

*RMS, MAE, MedAE e Dispersão em ADC Counts; R^2 é adimensional. Dispersão = média e desvio-padrão de σ_{erro} entre os 100 folds.




Fig. 2. Histogramas do erro de estimação da fase para ocupações (a) 10%, (b) 50%, (c) 80% e (d) 100%, comparando três abordagens de reconstrução: divisão pela amplitude estimada pelo OF, pela amplitude verdadeira e pela amplitude estimada pela CNN.

Observa-se que, para 10%, 50% e 80% de ocupação, as estimativas das CNNs apresentam distribuições de erro praticamente coincidentes com as obtidas pela amplitude real, indicando reconstruções de alta qualidade. Em contraste, o OF exibe maior dispersão conforme a ocupação aumenta, embora mantenha média próxima de zero, sugerindo que, apesar de não-enviesado, produz estimativas menos consistentes em alta ocupação. A Figura 3 complementa essa análise, mostrando a dispersão média da fase em função de intervalos de amplitude verdadeira.

Este resultado é particularmente relevante, pois os intervalos de baixa amplitude correspondem aos sinais mais frequentes no detector. Verifica-se que, nessa região, o OF apresenta dispersão consideravelmente maior em comparação às CNNs e à amplitude real. Consequentemente, uma parcela significativa das fases estimadas pelo OF está mais distante dos valores verdadeiros, comprometendo a precisão global do sistema justamente nos eventos mais comuns.

Embora as CNNs apresentem ganhos significativos em relação ao OF, há um custo computacional relevante: cada arquitetura demandou cerca de 6 horas de treinamento, frente a 10 minutos do OF, devido ao processamento de matrizes $21.999.934 \times 7$ ao longo dos 100 folds. Esse custo, porém, é único e *offline*; uma vez treinadas, as CNNs podem ser aplicadas em inferência em tempo real, com tempos compatíveis

com os requisitos de sistemas de *trigger* em calorimetria de altas energias.




Fig. 3. Dispersão média da estimação da fase para ocupações (a) 10%, (b) 50%, (c) 80% e (d) 100%, comparando o OF, a amplitude verdadeira e a melhor CNN por ocupação.

VI. CONCLUSÕES

Com base nos resultados obtidos, pode-se concluir que a aplicação de CNNs a séries temporais é altamente eficaz para a tarefa de reconstrução da amplitude e fase em sistemas de calorimetria de altas energias. As CNNs foram capazes de produzir estimativas consistentes e, em diversos cenários, superar o método linear tradicional do OF.

Os resultados também mostram que, com o aumento da ocupação, ruído e sobreposição de sinais (*pile-up*) se intensificam, degradando o desempenho de todos os métodos. Ainda assim, a degradação nas CNNs foi significativamente menor que no Filtro Ótimo. Computacionalmente, o custo das CNNs foi maior neste estudo devido à validação cruzada com *K-fold*, que exige um ciclo completo de treinamento por partição dos dados. Esse custo, porém, concentra-se na etapa de treinamento, tipicamente realizada *offline*.

Como perspectiva futura, o fluxo de processamento proposto deverá ser implementado e testado em processadores digitais de sinais modernos, como FPGA [24], adequados a arquiteturas de CNN, ainda que se espere alguma degradação por quantização dos pesos, a ser tratada com ajustes no modelo. Nesse cenário, o treinamento é realizado uma única vez, seguido pela aplicação direta a novos dados, reduzindo drasticamente o tempo de execução e tornando as CNNs competitivas para calorimetria de altas energias sob *pile-up* severo. Como trabalhos futuros, pretende-se avaliar a manutenção do pedestal, o uso de menos *folds* (e.g., 5 ou 10) frente aos 100 empregados, e CNNs mais compactas, quantificando o compromisso entre custo computacional e desempenho.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

REFERÊNCIAS

- [1] C. W. Fabjan and F. Gianotti, "Calorimetry for particle physics," *Rev. Mod. Phys.*, vol. 75, no. 4, pp. 1243–1286, 2003.
- [2] G. F. Knoll, *Radiation Detection and Measurement*, 4th ed. New York, NY, USA: John Wiley & Sons, 2010.
- [3] W. R. Leo, *Techniques for Nuclear and Particle Physics Experiments*. Berlin, Germany: Springer, 1994.
- [4] R. Wigmans, *Calorimetry: Energy Measurement in Particle Physics*. Oxford, U.K.: Oxford Univ. Press, 2017. doi: 10.1093/oso/9780198786351.001.0001.
- [5] G. Aad *et al.* (ATLAS Collaboration), "Readiness of the ATLAS Tile Calorimeter for LHC collisions," *Eur. Phys. J. C*, vol. 70, pp. 1193–1236, 2010.
- [6] S. Callier *et al.*, "SKIROC2, front-end chip designed to readout the Electromagnetic CALorimeter at the ILC," in *IEEE Nucl. Sci. Symp. Conf. Rec.*, 2009, pp. 1–6.
- [7] G. Apollinari *et al.*, "High-Luminosity Large Hadron Collider (HL-LHC): Technical Design Report," CERN Yellow Reports, vol. 4, 2017.
- [8] D. Belayneh *et al.*, "Calorimetry with deep learning: Particle simulation and reconstruction for collider physics," *Eur. Phys. J. C*, vol. 80, no. 7, p. 688, 2020. [Online]. Available: <https://arxiv.org/abs/1912.06794>
- [9] E. Buhmann *et al.*, "Getting high: High-fidelity simulation of high granularity calorimeters with high speed," *Comput. Softw. Big Sci.*, vol. 5, no. 1, p. 13, 2021. [Online]. Available: <https://arxiv.org/abs/2005.05334>
- [10] W. Cleland and E. Stern, "Signal processing considerations for liquid ionization calorimeters in a high-rate environment," *Nucl. Instrum. Methods Phys. Res., Sect. A*, vol. 338, pp. 467–497, 1994. doi: 10.1016/0168-9002(94)91332-3.
- [11] E. Fullana *et al.*, "Optimal filtering in the ATLAS hadronic Tile calorimeter," CERN, ATL-TILECAL-2005-001, 2005. [Online]. Available: <https://cds.cern.ch/record/816152>
- [12] G. Gonçalves, "PulseGenerator: Calorimetry pulse simulator," GitHub repository, 2024. [Online]. Available: <https://github.com/ingoncalves/calorimetry-pulse-simulator>
- [13] R. L. Workman *et al.* (Particle Data Group), "Review of particle physics," *Prog. Theor. Exp. Phys.*, 2022, 083C01. [Online]. Available: <https://pdg.lbl.gov/2021/reviews/tpp2021-rev-particle-detectors-accel.pdf>
- [14] M. V. Araújo *et al.*, "Lorenzetti Showers – A general-purpose framework for supporting signal reconstruction and triggering with calorimeters," *Comput. Phys. Commun.*, vol. 286, p. 108671, 2023. doi: 10.1016/j.cpc.2023.108671.
- [15] E. F. Simas Filho *et al.*, "Ring-like calorimeter information for energy calibration in electron trigger at a highly segmented detector using gradient boosted decision trees," *J. Instrum.*, vol. 20, no. 06, p. P06051, Jun. 2025. doi: 10.1088/1748-0221/20/06/P06051.
- [16] S. Agostinelli *et al.* (GEANT4 Collaboration), "GEANT4: A simulation toolkit," *Nucl. Instrum. Methods Phys. Res., Sect. A*, vol. 506, pp. 250–303, 2003.
- [17] F. Pitters *et al.* (CMS Collaboration), "The CMS high-granularity calorimeter for operation at the High-Luminosity LHC," arXiv:1802.05987, 2018.
- [18] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. Cambridge, MA, USA: MIT Press, 2016. [Online]. Available: <http://www.deeplearningbook.org>
- [19] S. Kiranyaz, T. Ince, and M. Gabbouj, "1D convolutional neural networks for signal processing applications," *IEEE Trans. Signal Process.*, vol. 67, no. 20, pp. 540–554, 2019. doi: 10.1109/TSP.2019.2935795.
- [20] G. I. Gonçalves, B. S. Peralva, J. M. Seixas, L. M. A. Filho, and A. S. Cerqueira, "Performance of optimal linear filtering methods for signal estimation in high-energy calorimetry," *Journal of Control, Automation and Electrical Systems*, pp. 1–11, 2022. doi: 10.1007/s40313-022-00907-0.
- [21] S. M. Rimes, B. S. Peralva, G. B. Libotte, T. C. A. Paschoalin, L. M. d. A. Filho and J. M. De Seixas, "A Maximum Likelihood Approach for Signal Estimation and Data Quality Assessment for High-Energy Calorimeter Systems," in *IEEE Transactions on Nuclear Science*, 2025. doi: 10.1109/TNS.2025.3630987.
- [22] J. Chapman, "ATLAS Simulation Computing Performance and Pile-up Simulation in ATLAS," in LPCC Detector Simulation Workshop, (CERN, Meyrin, CH), 2011. Available at: LPCCTalk20111007.pdf, accessed on July 23, 2025.
- [23] D. A. Cardinot, B. S. Peralva, G. B. Libotte, and L. de M. A. Filho, "Convolutional Neural Networks for Energy Estimation in High-Energy Calorimetry," in *Proc. IEEE 27th Latin American Test Symposium (LATS)*, 2026, pp. 1–6. doi: 10.1109/LATS70329.2026.11480323.
- [24] J. Meyer-Baese, *Digital signal processing with field programmable gate arrays*, 4th ed. Berlin, Germany: Springer, 2014. doi: 10.1007/978-3-642-45309-0.