

Sistema de Filtragem Online de Elétrons Utilizando CNNs em um Detector de Partículas Finamente Segmentado com Elevado Empilhamento de Sinais

Isaac P. C. Araujo, Edmar E. P. de Souza, Isabella Silva Ferreira, José Manoel de Seixas, Eduardo F. de Simas Filho

Resumo— A fase de alta luminosidade (Run 4) do experimento ATLAS no CERN demandará sistemas eficientes de filtragem online de partículas sob severo empilhamento de sinais. Este trabalho propõe uma abordagem baseada em Redes Neurais Convolucionais integrada ao algoritmo NeuralRinger para operar no Nível 0 de filtragem online de elétrons. Investigou-se o impacto da redução progressiva do vetor de atributos de 100 para 50 e 25 anéis concêntricos de energia da partícula incidente. Os resultados mostram que as arquiteturas propostas superam os modelos MLP tradicionais, reduzindo as taxas de alarme falso e mantendo elevada eficiência de identificação de elétrons.

Palavras-Chave— Filtragem Online, Redes Neurais Convolucionais, Redução Dimensional, Experimento ATLAS.

Abstract— The high-luminosity phase (Run 4) of the ATLAS experiment at CERN will demand efficient online particle filtering systems under severe signal pile-up conditions. This work proposes an approach based on Convolutional Neural Networks integrated with the NeuralRinger algorithm to operate at the Level 0 online electron filtering stage. The impact of progressively reducing the feature vector from 100 to 50 and 25 concentric rings of the incident particle's energy was investigated. The results show that the proposed architectures outperform traditional MLP models, reducing false alarm rates while maintaining high electron identification efficiency.

Keywords— Online Filtering, Convolutional Neural Networks, Dimensionality Reduction, ATLAS Experiment.

I. INTRODUÇÃO

Experimentos de física de altas energias são dotados de uma complexa infraestrutura tecnológica, para prover medidas precisas das forças e interações subatômicas. O Experimento ATLAS, do Grande Colisor de Hádrons (*Large Hadron Collider*) localizado no CERN - Suíça, é um dos maiores experimentos de física de partículas já construídos, com um vasto programa de física para melhorar a compreensão do Modelo Padrão da Física de Partículas, bem como fenômenos ainda não verificados experimentalmente. A fase de operação de alta luminosidade (*High Luminosity - LHC*) prevista para iniciar suas operações em 2030 [1], promoverá um aumento na taxa de registro de dados de 7 a 10 vezes maior que a atual [2], elevando o volume de dados brutos na entrada dos sistemas de filtragem para aproximadamente 70 TB/s. Esse

cenário resultará em condições extremas de operação, com o nível médio de colisões por cruzamento de pacotes (*pile-up*) saltando dos atuais 30–60 para até 200 [1], o que causará distorções nas amostras da energia das partículas medidas nos sistemas de calorimetria do detector.

Para lidar com esse novo cenário trazido pela *Run 4*, planeja-se um novo sistema de identificação online de eventos operando em Nível 0 (L0), baseado em *hardware* dedicado, para selecionar os eventos de interesse e remover o máximo possível de ruído de fundo. Diante disso, este trabalho propõe uma abordagem baseada em Redes Neurais Convolucionais (CNN) aplicada ao algoritmo *NeuralRinger*, em contraponto a atual versão do algoritmo, que utiliza Rede Neurais Multicamadas (*Multi-Layer Perceptrons - MLP*) já consolidado na operação do sistema de classificação online de elétrons e fótons no ATLAS. A estratégia, ainda, visa extrair os atributos de entrada (anéis concêntricos) e analisar os efeitos da redução de células na eficiência de detecção do sistema de classificação.

II. O EXPERIMENTO ATLAS, O SISTEMA DE *Trigger* E O ALGORITMO *NeuralRinger*

O ATLAS possui aproximadamente 25m de altura e 44 de comprimento, contando com uma estrutura cilíndrica que cobre aproximadamente 99% de todo o ângulo sólido em torno do ponto de colisão, conforme a Figura 1.




Fig. 1. Representação gráfica do experimento ATLAS, extraído de [2].

O sistema de calorimetria do ATLAS circunda o detector interno e é composto por calorímetros de amostragem baseados em argônio líquido (LAr) [2], [5]. Este sistema possui

Isaac P. C. Araujo, Edmar Egidio Purcino de Souza e Eduardo F. de Simas Filho fazem parte do Programa de Pós Graduação em Engenharias Elétrica e de Computação da Universidade Federal da Bahia, e-mails: isaacpca@ufba.br; edmar.egidio@ufba.br; eduardo.simas@ufba.br. Isabella Silva Ferreira e José Manoel de Seixas estão vinculados ao Programa de Engenharia Elétrica da COPPE/UFRJ, e-mails: isabella.ferreira@lps.ufrj.br, seixas@lps.ufrj.br.

cobertura azimutal total (ϕ) e estende-se na faixa de pseudo-rapidez $|\eta| < 4,9$, subdividindo-se em seções eletromagnética (ECAL) e hadrônica (HCAL) [2]. Geometricamente, a região central (*barrel*) divide-se em duas metades ($-1,475 \leq \eta < 0$ e $0 < \eta \leq 1,475$), enquanto os componentes de extremidade (*end-caps*) cobrem o intervalo $1,375 < |\eta| \leq 3,2$ [2]. Na região de transição ($1,37 < |\eta| \leq 1,54$), há uma redução de material ativo (*crack region*) devido à passagem de cabos e conexões estruturais, além de uma junção mecânica entre as tampas cilíndricas na faixa $2,37 < |\eta| \leq 2,47$ [2].

Na região de alta precisão ($|\eta| < 2,5$), excluindo o *crack*, o ECAL é segmentado em três camadas longitudinais (EM1, EM2 e EM3) na direção de profundidade do chuveiro [2]. O detector é projetado para que a maior fração da energia do elétron seja depositada em EM2, restando à EM3 a coleta da cauda do chuveiro eletromagnético. O HCAL é composto por três camadas longitudinais (HAD1, HAD2 e HAD3) destinadas a medir a energia de partículas hadrônicas [2]. Adicionalmente, uma camada fina de LAr, o pré-amostrador (*Presampler* - PS), cobre o intervalo $|\eta| < 1,8$ para estimar a perda energética das partículas antes de atingirem os calorímetros principais [2].

O ATLAS é dotado de um sistema de filtragem e aquisição de dados (TDAQ - Trigger and Data Acquisition) [6], responsável por decidir se deve registrar eventos de uma determinada colisão. Devido à previsão do aumento da luminosidade e do empilhamento (*pile-up*) de sinais para a *Run 4*, uma nova arquitetura para o TDAQ foi proposta, onde foi acrescido o nível zero (L0) de reconstrução e filtragem de eventos e tem sido projetado para operação em *hardware*.

De modo geral, os atributos utilizados para a construção dos sistemas de classificação do TDAQ são extraídos das cascatas de energia geradas da interação das partículas com o material dos sistemas de calorimetria, os chamados chuveiros eletromagnéticos e hadrônicos. Esses chuveiros são produzidos a partir do decaimento dos elétrons e hádrons, que se espalham por uma região lateralmente mais ampla do calorímetro, conforme o seu desenvolvimento longitudinal, obtendo um aspecto cônico.

A propriedade dos chuveiros de partículas de se desenvolver lateralmente em um formato aproximadamente cônico longitudinalmente em torno da partícula inicial é explorada pelo algoritmo *NeuralRinger* [4]. O método é composto por uma parametrização concêntrica da deposição energética a partir da célula mais energética (*hot cell*) de cada camada longitudinal, somando cumulativamente a energia das células vizinhas em anéis concêntricos sucessivos, como indicado na Figura 2. Esse mapeamento estende-se longitudinalmente pelas seções eletromagnética e hadrônica, gerando um vetor plano de referência com 100 anéis (v0), distribuídos em camadas como demonstrado na Tabela I.

Diante do sucesso operacional obtido na *Run 2* [7] e *Run 3*, este trabalho investiga a capacidade de modelos compostos por Redes Neurais Convolucionais junto ao algoritmo *NeuralRinger* na identificação de elétrons, em contraponto à tradicional arquitetura Perceptron de Múltiplas Camadas (MLP), visando uma futura implementação no sistema de *trigger* da *Run 4*. Devido ao cenário de severas restrições de largura de




Fig. 2. Ilustração do procedimento de formatação da energia das partículas em anéis concêntricos do Algoritmo NeuralRinger [3].

TABELA I

NÚMERO MÁXIMO DE ANÉIS CONSTITUINTES GERADOS EM CADA CAMADA DOS CALORÍMETROS DO EXPERIMENTO ATLAS PARA A TOPOLOGIA DE REFERÊNCIA V0.

PS	EM1	EM2	EM3	HAD1	HAD2	HAD3	Total
8	64	8	8	4	4	4	100

banda passante projetado, avaliou-se o impacto da redução progressiva dos atributos de entrada sobre a eficiência global do sistema de classificação convolucional proposto. A partir dos resultados desta investigação, serão propostos em trabalhos futuros a sua implementação em *hardware* [8].

III. METODOLOGIA PROPOSTA

A. Conjunto de Dados Utilizados

O conjunto de dados utilizado neste trabalho adota a metodologia de filtragem online proposta por Ferreira et al. [3], na qual aplica-se um limiar de corte de 2σ para a supressão do ruído eletrônico e de empilhamento (*pile-up*) nas células do calorímetro. Para fins de análise comparativa, utilizou-se a mesma base de dados emulada para o *Run 4* do experimento ATLAS disponibilizada pelos referidos autores, onde o nível de empilhamento $\mu = 60$, referente à *Run 3*.

Neste cenário, os eventos simulados de sinal compreendem o decaimento do bóson Z em um par elétron-pósitron ($Z \rightarrow e^+e^-$). Enquanto, o (*background*) é composto por elétrons provenientes de interações hadrônicas (jatos). Em ambos os casos, selecionou-se candidatos com energia transversa (E_T) superior a 15 GeV^1 , delimitados por intervalos de pseudo-rapidez (η). Essa discretização permite avaliar a robustez dos classificadores frente às variações geométricas do detector e aos diferentes níveis de energia das partículas incidentes, conforme a Figura 3.

A estratégia experimental deste trabalho foi dividida em três fases consecutivas. Primeiro, uma arquitetura de Rede Neural Convolucional foi treinada e avaliada individualmente em cada uma das regiões do espaço pré-definido na Figura 3, utilizando

¹Um elétron-volt (eV) é uma unidade de medida de energia que, equivale à quantidade de energia cinética que um elétron ganha (ou perde) ao ser acelerado através de uma diferença de potencial elétrico de (volt) no vácuo




Fig. 3. Quantidade de amostras disponíveis para treinamento e teste dos modelos neurais (azul para classe de sinal, vermelho para classe *background*), adaptado de [3].

os mesmos pontos de operação (*Trigger thresholds*) mapeados pelo modelo Multicamadas (MLP) de referência. A partir dessa validação inicial, realizou-se a redução de dimensionalidade do vetor de atributos, células (anéis), da topologia original do *NeuralRinger*. Em seguida, investigou-se o impacto da redução progressiva da quantidade de anéis concêntricos na eficiência de detecção dos classificadores na região central do barril, com energia transversa moderada alta, além do resultado integralizado de toda a região discretizada do detector.

B. Configurações de Treinamento das CNNs

Em contraponto à arquitetura de referência composta por uma MLP [3], este trabalho propõe um modelo composto por camadas convolucionais e densas. As especificações estruturais, hiperparâmetros de treinamento e as principais divergências de projeto entre ambos os modelos estão sintetizados na Tabela II.

A transição para a topologia convolucional modifica a dinâmica do aprendizado de máquina sobre os sinais dos calorímetros. Enquanto o modelo MLP de referência [3] realiza combinações lineares globais sobre o vetor plano de 100 anéis, a CNN 1D proposta emprega o mecanismo de compartilhamento de pesos através de seus filtros lineares. Esse arranjo permite mapear padrões invariáveis à translação entre anéis adjacentes, reduzindo consideravelmente o número de parâmetros independentes e otimizando a capacidade de generalização do classificador online. Como o principal objetivo deste trabalho é validar a viabilidade do uso de Redes Convolucionais frente às clássicas MLPs, optou-se por projetar uma versão simplificada de arquitetura CNN. Dessa forma, os hiperparâmetros, incluindo os tamanhos dos filtros (*Kernels*), foram definidos de modo empírico para cada fator de compressão, no qual não houve a realização de um processo de ajuste fino, ou *fine-tuning* do modelo.

Na avaliação do impacto da redução dimensional, além da versão de referência contendo o total de 100 anéis (v0), foram desenvolvidas duas variantes adaptadas: a versão v1, que reduz

TABELA II
COMPARATIVO ESTRUTURAL E DE HIPERPARÂMETROS ENTRE A ARQUITETURA MLP DE REFERÊNCIA E AS VARIAÇÕES DA CNN 1D PROPOSTA (v0, v1 E v2).

Descrição	MLP [3]	CNN v0	CNN v1	CNN v2
Dimensão de Entrada	100×1 (Plano)	100×1 (Sinal)	50×1 (Sinal)	25×1 (Sinal)
Camadas Conv.	Não Apl.	2 (Conv1D)	2 (Conv1D)	2 (Conv1D)
Num. Filtros	Não Apl.	16 / 32	16 / 32	16 / 32
Tam. <i>Kernel</i>	Não Apl.	$K = 11$	$K = 7$	$K = 4$
Camadas <i>Pooling</i>	Não Apl.	2 (Max)	2 (Max)	2 (Max)
Redução Global	Não Apl.	GlobalAvg	GlobalAvg	GlobalAvg
Camadas Densas	1 (5 nós)	1 (16 nós)	1 (16 nós)	1 (16 nós)
Ativação (Ocultas)	ReLU	ReLU	ReLU	ReLU
Camada de Saída	1 (Sigm.)	1 (Sigm.)	1 (Sigm.)	1 (Sigm.)
Função de Perda	Entr. Bin.	Entr. Bin.	Entr. Bin.	Entr. Bin.
Tam. Batelada	1024	512	512	512
Máximo Épocas	5000	5000	5000	5000
Critério Parada	Máx. SP	Máx. SP	Máx. SP	Máx. SP
Parada Antec.	25 ép.	25 ép.	25 ép.	25 ép.
Valid. Cruzada	k -fold Es- tra. ($k = 10$)	k -fold ($k = 10$)		

os atributos para 50 anéis, e a versão v2, operando com 25 anéis. A redução dimensional foi executada de forma proporcional ao fator de compressão de cada variante, realizando-se o corte dos atributos dos anéis periféricos para os centrais. Cada cenário está sintetizado na Tabela III.

TABELA III
DISTRIBUIÇÃO DE ANÉIS POR CAMADA DO CALORÍMETRO PARA AS VERSÕES AVALIADAS COM A CNN 1D.

Camada do Calorímetro	v0	v1	v2
<i>Presampler</i>	8	4	2
EM1	64	32	16
EM2	8	4	2
EM3	8	4	2
HAD1	4	2	1
HAD2	4	2	1
HAD3	4	2	1
Total de Atributos	100	50	25
Fator de Compressão	$1 \times$	$2 \times$	$4 \times$

C. Medidas de Avaliação e Pontos de Operação

Para avaliar o desempenho dos classificadores desenvolvidos e garantir uma comparação direta com o modelo MLP de referência [3], foram utilizadas a probabilidade de detecção de elétrons (P_D), a probabilidade de falso alarme (F_A) e o índice Soma-Produto (SP). A P_D mede a fração de elétrons corretamente identificados pelo sistema, enquanto a F_A quantifica a proporção de jatos hadrônicos incorretamente classificados como sinal. Ambas são combinadas no Índice SP , que estima

o equilíbrio entre o desempenho de identificação de elétrons e aceitação de jatos hadrônicos classificados como elétrons, definido matematicamente por:

$$SP = \sqrt{\sqrt{P_D \cdot (1 - F_A)} \cdot \frac{P_D + (1 - F_A)}{2}} \quad (1)$$

Foi adotado o método de validação cruzada estratificada em k -folds ($k = 10$), associado a um procedimento de 5 inicializações aleatórias e independentes de pesos para cada um dos subconjuntos do *fold*. Esse arranjo totaliza 50 candidatos a classificadores por cenário, mitigando efeitos de convergência para mínimos locais e melhorando a estabilidade estatística das curvas de aprendizado. A escolha do melhor *fold* baseou-se no maior Índice SP dentre os candidatos, enquanto as repetições do *fold* escolhido foram utilizadas para avaliar a estabilidade de desempenho e sensibilidade aos dados do modelo.

Para a avaliação dos resultados com um conjunto de teste, foram escolhidos dois pontos de operação do sistema de classificação distintos: os critérios *Very Loose*, que possui um limiar de decisão da rede neural mais permissivo e foca na alta eficiência de detecção de sinal e *Tight*, que detém um critério mais rigoroso aplicado à seleção de elétrons.

IV. RESULTADOS

A avaliação do impacto da redução dimensional do vetor de atributos é uma etapa crítica para viabilizar a operação contínua do sistema de filtragem online do experimento ATLAS sob condições extremas de empilhamento. É importante ressaltar que, atualmente, o sistema de *trigger* do experimento já emprega operacionalmente uma topologia consolidada de 50 anéis (v1).

A Figura 4 apresenta o comportamento do perfil médio de deposição de energia das partículas à medida que se reduz a quantidade dos atributos da versão de referência de 100 anéis (v0) para a configuração operacional de 50 anéis (v1) e a topologia proposta com 25 anéis (v2). Observa-se que a extração das células preserva a assinatura física do sinal, mantendo picos energéticos de Elétron e Jatos na camada EM1, assim como a alta concentração de energia depositada em EM2. Entretanto, na topologia v2, ocorre uma maior perda de resolução fina e uma fusão de sinais entre as regiões hadrônicas, devido à diminuição brusca da quantidade de anéis nas regiões HAD1, HAD2 e HAD3.

Conforme ilustrado na Figura 5, observa-se que tanto para a curva de perda quanto para a acurácia, os perfis obtidos nos conjuntos de treinamento e validação das topologias v1 e v2 apresentam um comportamento assintótico e convergente na região de $30 < E_T \leq 40$ GeV e $0,0 < \eta \leq 0,8$. Essa aderência e similaridade entre as curvas de treino e validação propõem uma capacidade de generalização e estabilidade do modelo escolhido via critério de maximização do Índice SP .

As curvas Características de Operação do Receptor (ROC) obtidas no conjunto de teste para as topologias v1 e v2 (Figura 6) indicam que os modelos propostos alcançam uma elevada probabilidade de detecção (P_D), associada a baixas taxas de alarme falso (F_A). A utilização da validação cruzada estratificada com múltiplas inicializações independentes viabilizou




Fig. 4. Impacto da redução progressiva de atributos no perfil médio de deposição de energia para as variantes v0 (100 anéis), v1 (50 anéis) e v2 (25 anéis) na região de $30 < E_T \leq 40$ GeV e $0,0 < \eta \leq 0,8$.




Fig. 5. Evolução das curvas de perda, acurácia para os modelos CNN v1 (50 Anéis) e v2 (25 Anéis) na região de $30 < E_T \leq 40$ GeV e $0,0 < \eta \leq 0,8$.

o mapeamento da estabilidade dos pontos de operação do ATLAS: *Tight*, *Medium*, *Loose* e *Very Loose*. Os resultados extraídos mostram que, na região central do barril, numa área de energia transversa moderada alta ($30 < E_T \leq 40$ GeV e $0,0 < \eta \leq 0,8$), a topologia v1 (50 anéis) estabelece uma taxa média de falso alarme de apenas 1,410% para o ponto *Tight*, expandindo-se estavelmente até 2,180% no critério *Very Loose*. Além disso, na versão de 25 anéis (v2), o modelo retém sua robustez discriminatória, apresentando taxas médias de 1,720% e 2,330% para os extremos *Tight* e *Very Loose*, respectivamente.

Nesta região, a extração dos anéis não representou um aumento significativo da taxa de falso alarmes, além de manter valores aceitáveis de dispersão estatística, em *Tight* e *Very Loose*.

Os resultados integralizados obtidos para toda a faixa dinâmica acima de 15 GeV estão indicados nas Tabelas IV




Fig. 6. Curvas ROC de teste e estabilidade dos pontos de operação (*Tight*, *Medium*, *Loose* e *Very Loose*) para o melhor *fold* operacional das topologias v1 e v2.

e V, avaliando os pontos de operação *Tight* e *Very Loose*, respectivamente. As informações revelam que as arquiteturas CNN 1D propostas superaram consistentemente os modelos baseados em redes densas (MLP) de referência [3], mantendo a mesma eficiência de sinal (P_D) estabelecida pelos critérios operacionais do experimento ATLAS. No ponto de operação (*Tight*), o modelo proposto para v1 (50 anéis) reduziu a Probabilidade de Falso Alarme (F_A) de 5,26% para 4,02%. O impacto mais expressivo manifesta-se sob o cenário para (v2 - 25 anéis), no qual o classificador MLP sofria uma severa degradação, elevando o F_A para 11,63%. Em contrapartida, a CNN 1D v2 conseguiu conter essa taxa em 5,38%, um desempenho paralelo ao modelo MLP que utiliza o dobro de atributos (v1). Comportamento similar é observado no ponto *Very Loose*, onde os modelos convolucionais v1 e v2 registraram taxas de falso alarme de 6,52% e 9,03%, contrapondo-se aos patamares de 8,83% e 16,72% das respectivas contrapartes densas.

TABELA IV

COMPARATIVO DE DESEMPENHO PARA TODA A FAIXA DINÂMICA ACIMA DE 15 GEV NO PONTO DE OPERAÇÃO *Tight*.

Topologia / Trabalho	P_D [%]	F_A [%]
Referência	99,58	5,13
v0 MLP [3]	$99,58 \pm 0,01$	$4,76 \pm 0,23$
v1 MLP [3]	$99,59 \pm 0,01$	$5,26 \pm 0,22$
v1 CNN 1D (Proposto)	$99,59 \pm 0,01$	$4,02 \pm 0,19$
v2 MLP [3]	$99,58 \pm 0,01$	$11,63 \pm 0,60$
v2 CNN 1D (Proposto)	$99,59 \pm 0,01$	$5,38 \pm 0,26$

Adicionalmente, nota-se uma redução nas incertezas as-

TABELA V

COMPARATIVO DE DESEMPENHO PARA TODA A FAIXA DINÂMICA ACIMA DE 15 GEV NO PONTO DE OPERAÇÃO *Very Loose*.

Topologia / Trabalho	P_D [%]	F_A [%]
Referência	99,84	8,33
v0 MLP [3]	$99,85 \pm 0,01$	$8,19 \pm 2,47$
v1 MLP [3]	$99,84 \pm 0,01$	$8,83 \pm 2,42$
v1 CNN 1D (Proposto)	$99,85 \pm 0,01$	$6,52 \pm 0,73$
v2 MLP [3]	$99,84 \pm 0,01$	$16,72 \pm 2,57$
v2 CNN 1D (Proposto)	$99,85 \pm 0,01$	$9,03 \pm 0,98$

sociadas das taxas de falso alarme, alcançando intervalos consideravelmente menores (da ordem de $\pm 0,73\%$ a $\pm 0,98\%$) quando comparadas às oscilações da MLP (que atingem até $\pm 2,57\%$).

V. CONCLUSÕES

Este trabalho demonstrou que a abordagem baseada em Redes Neurais Convolucionais (CNN) aplicada ao algoritmo *NeuralRinger* é robusta para a filtragem online de elétrons do experimento ATLAS e com grande potencial para avaliação sob as condições projetadas para a *Run 4*. Os resultados integrados revelaram que as variantes propostas (v1 CNN 1D e v2 CNN 1D) superaram consistentemente os classificadores MLP de referência de mesma topologia, reduzindo de forma expressiva a taxa de alarmes falsos (F_A) e mantendo índices de dispersão estatística controlados. Como perspectivas e próximos passos desta pesquisa, planeja-se a avaliação detalhada do impacto dessa redução dimensional de atributos discriminantes nas diferentes faixas discretizadas de pseudorapidez (η), além da investigação, ajuste fino (*tuning*) e otimização de novas variações estruturais para as arquiteturas convolucionais com maior número de eventos e amostras para um nível empilhamento (*pile-up*) $\mu = 200$.

REFERÊNCIAS

- [1] LHC Experiments Committee (LHCC), “Strategic review of HL-LHC computing,” CERN, Geneva, Tech. Rep. CERN-LHCC-2020-007 / LHCC-G-182, 2020.
- [2] ATLAS Collaboration, “The ATLAS Experiment at the CERN Large Hadron Collider,” *Journal of Instrumentation*, vol. 3, no. 08, pp. S08003–S08003, aug 2008.
- [3] I. S. Ferreira, J. M. de Seixas, E. E. P. de Souza e D. O. Damazio, “Conjunto de Redes Neurais para Seleção Online de Elétrons em um Calorímetro Finamente Segmentado e com Elevada Taxa de Empilhamento de Sinais,” em *Anais do Simpósio Brasileiro de Telecomunicações e Processamento de Sinais (SBrt)*, Natal, RN, Brasil, 2025.
- [4] E. E. P. de Souza, *Conjunto de Classificadores Neurais Alimentados por Informação Especialista para Filtragem Online em um Detector de Partículas*, Tese de Doutorado, PPGEE, Universidade Federal da Bahia (UFBA), Salvador, BA, Brasil, 2021.
- [5] R. Wigmans, *Calorimetry: Energy Measurement in Particle Physics*, International Series of Monographs on Physics, Clarendon Press, 2017.
- [6] ATLAS-COLLABORATION, “The ATLAS Data Acquisition and High LevelTrigger system”, *Journal of Instrumentation*, v. 11, n. 06, jun 2016.
- [7] G. Aad, Abbott et al., “Performance of electron and photon triggers in ATLAS during *lhc run 2*,” *Eur. Phys. J. C*, vol. 80, p. 47. 56 p, Sep 2019.
- [8] Igo Amauri Dos Santos Luz and Gabriel Henrique Braga Lisboa and Nestor Pereira Neto, et al. Redes Neurais Embarcadas em FPGA para Classificação Online de Elétrons em um Calorímetro de Altas Energias, *Anais do XVII Congresso Brasileiro de Inteligência Computacional (CBIC 2025)*.