



UNIVERSIDADE FEDERAL DA BAHIA
ESCOLA POLITÉCNICA

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIAS ELÉTRICA E DE COMPUTAÇÃO

CAROLINE RIBEIRO FIGUEREDO

Dissertação de Mestrado

**CALIBRAÇÃO DAS MEDIÇÕES DE ENERGIA EM
UM DETECTOR DE PARTÍCULAS UTILIZANDO
INFORMAÇÕES DE ASSIMETRIA DO PERFIL DE
DEPOSIÇÃO NO CALORÍMETRO E TÉCNICAS DE
INTELIGÊNCIA ARTIFICIAL**

Salvador

Julho, 2025

**CALIBRAÇÃO DAS MEDIÇÕES DE ENERGIA EM UM DETECTOR DE PARTÍCULAS
UTILIZANDO INFORMAÇÕES DE ASSIMETRIA DO PERFIL DE DEPOSIÇÃO NO
CALORÍMETRO DO EXPERIMENTO ATLAS E TÉCNICAS DE INTELIGÊNCIA
ARTIFICIAL**

CAROLINE RIBEIRO FIGUEREDO

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharias Elétrica e de Computação da Escola Politécnica da Universidade Federal da Bahia como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia Elétrica e de Computação.

Banca examinadora:



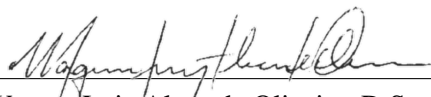
Prof. Paulo César Machado de Abreu Farias, D.Sc. (Orientador) - UFBA



Prof. Antônio Carlos Lopes Fernandes Júnior, D.Sc. - UFBA



Prof. Roberto Célio Limão de Oliveira, D.Sc. - UFPA



Prof. Wagner Luiz Alves de Oliveira, D.Sc. - UFBA

Salvador, 22 de julho de 2025.



Ata da Sessão Pública de Defesa de dissertação de mestrado de Caroline Ribeiro Figueredo do Programa de Pós-Graduação em Engenharias Elétrica e de Computação da UFBA

Ata da sessão pública do PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIAS ELÉTRICA E DE COMPUTAÇÃO (PPGEEC), realizada em 22/07/2025 para procedimento de defesa da Dissertação de MESTRADO EM ENGENHARIA ELÉTRICA no. 290, área de concentração Processamento de Informação e Energia, da candidata CAROLINE RIBEIRO FIGUEREDO, de matrícula 2022120330, intitulada “Calibração das Medições de Energia em um Detector de Partículas Utilizando Informações de Assimetria do Perfil de Deposição no Calorímetro e Técnicas de Inteligência Artificial”, orientada pelos docentes Prof. Dr. PAULO CESAR MACHADO DE ABREU FARIAS e Prof. Dr. EDUARDO FURTADO DE SIMAS FILHO. Às 09:00 do citado dia, em <https://conferenciaweb.rnp.br/sala/paulo-cesar-machado-de-abreu-farias>, foi aberta a sessão pelo presidente da banca examinadora Prof. Dr. PAULO CESAR MACHADO DE ABREU FARIAS que apresentou os demais membros da banca: Prof. Dr. ANTONIO CARLOS LOPES FERNANDES JUNIOR, Prof. Dr. WAGNER LUIZ ALVES DE OLIVEIRA e Prof. Dr. ROBERTO CÉLIO LIMÃO DE OLIVEIRA. Em seguida foram esclarecidos os procedimentos pelo presidente que passou a palavra à examinada para apresentação do trabalho de Mestrado. Ao final da apresentação, passou-se à arguição por parte da banca, a qual, em seguida, reuniu-se para a elaboração do parecer. No seu retorno, foi lido o parecer final a respeito do trabalho apresentado pela candidata, tendo a banca examinadora aprovado o trabalho apresentado, sendo esta aprovação um requisito parcial para a obtenção do grau de Mestre. Em seguida, nada mais havendo a tratar, foi encerrada a sessão pelo presidente da banca, tendo sido, logo a seguir, lavrada a presente ata, abaixo assinada por todos os membros da banca e pela candidata.

Salvador, 22 de Julho de 2025.

Prof. Dr. Paulo César Machado de Abreu Farias Prof. Dr. Roberto Célio Limão de Oliveira

Prof. Dr. Antonio Carlos Lopes Fernandes Junior Prof. Dr. Wagner Luiz Alves de Oliveira

Caroline Ribeiro Figueredo

F475 Figueredo, Caroline Ribeiro.

Calibração das medições de energia em um detector de partículas utilizando informações de assimetria do perfil de deposição no calorímetro do experimento atlas e técnicas de inteligência artificial / Caroline Ribeiro Figueredo. – Salvador, 2025.

99f.: il.; color.

Orientador: Prof. Dr. Paulo César Machado de Abreu Farias.

Dissertação (mestrado) – Programa de Pós-Graduação em Engenharias Elétrica e de Computação, Escola Politécnica, Universidade Federal da Bahia, 2025.

1. Calibração - energia. 2. Atlas - detector. 3. Modelagem. 4. Inteligência artificial. I. Farias, Paulo César Machado de Abreu. II. Universidade Federal da Bahia. III. Título.

CDD: 681.2

Ficha catalográfica elaborada pela Biblioteca Bernadete
Sinay Neves, Escola Politécnica – UFBA.

Lista de Figuras

Figura 1	– Representação do Modelo Padrão de Partículas, dividido em partículas de matéria e portadores de força. [7]	15
Figura 2	– Representação da cadeia de injeção do LHC. Os prótons são acelerados em etapas por quatro aceleradores distintos antes de serem injetados no LHC. [22]	19
Figura 3	– O experimento ATLAS e seus subsistemas. [23]	20
Figura 4	– Sistema de coordenadas do calorímetro ATLAS. Adaptado da tese de Simas Filho [25], com modificações feitas por André Paiva.	20
Figura 5	– Ilustração em corte do detector interno ATLAS. [28]	21
Figura 6	– Ilustração das assinaturas que as partículas deixam ao atravessar o detector ATLAS. [29]	22
Figura 7	– Ilustração em corte do sistema calorímetro ATLAS. [32]	23
Figura 8	– <i>Layout</i> da camada de sinal para os quatro tipos diferentes de eletrodos antes de dobrar. O dois eletrodos superiores são para o cilindro e os dois eletrodos inferiores são para a tampa interna (esquerda) e rodas externas (direita). As dimensões estão em milímetros. Os desenhos estão todos na mesma escala. [33]	25
Figura 9	– Esboço de um módulo de barril onde as diferentes camadas são claramente visíveis com o agrupamento de eletrodos em ϕ . A granularidade em η e ϕ das células de cada uma das três camadas e da torres de gatilho também são mostradas [33]	25
Figura 10	– Esboço do trabalho de processamento de dados eletrônicos realizado durante 2017 e 2018 - coleta de dados [35].	28
Figura 11	– Diagrama do processo de construção dos anéis. Devido à estrutura das células do calorímetro, esses anéis têm forma retangular. [36]	28
Figura 12	– Diagrama simplificado do processo de construção dos anéis. Devido à estrutura das células do calorímetro, esses anéis têm forma retangular. [11]	29
Figura 13	– Diagrama do sistema de seleção <i>online</i> (<i>trigger</i>) de elétrons do detector ATLAS [11].	31
Figura 14	– Ilustração das principais causas dos erros na estimação da energia total da partícula ao interagir com o calorímetro do ATLAS [11].	33
Figura 15	– Perfil de distribuição em E_t .	37
Figura 16	– Perfil de distribuição em η .	37
Figura 17	– Métodos utilizados para a calibração do calorímetro.	39
Figura 18	– Gráfico dos perfis de energia depositada dos <i>Standard Rings</i>	47
Figura 19	– Gráfico dos perfis de energia depositada dos <i>Quarter Rings</i>	47
Figura 20	– Gráfico da distribuição da energia depositada de forma assimétrica por anel na camada EM2, no evento 15.	48
Figura 21	– Assimetria do fluxo de energia para um conjunto de <i>Quarter Rings</i> na camada EM2, em relação a η .	49
Figura 22	– Assimetria do fluxo de energia para um conjunto de <i>Quarter Rings</i> na camada EM2 em relação a Φ .	49
Figura 23	– Assimetria do fluxo de energia para um conjunto de <i>Quarter Rings</i> na camada EM2 em relação a η .	50

Figura 24 – Comportamento do IQR do fator α , em função de η , sem a presença de <i>pile-up</i>	51
Figura 25 – Comportamento do IQR do fator α , em função da energia, sem a presença de <i>pile-up</i>	52
Figura 26 – Gráfico de resolução em função da energia na faixa de 40 a 50 GeV, sem a presença de <i>pile-up</i>	53
Figura 27 – Comportamento do IQR do fator α , em função da η , com <i>pile-up</i> $< \mu >$ na faixa de 25 a 52.	55
Figura 28 – Comportamento do IQR do fator α , em função da energia, com <i>pile-up</i> $< \mu >$ na faixa de 25 a 52.	56
Figura 29 – Gráfico de resolução em função da energia na faixa de 40 a 50 GeV, considerando o efeito <i>pile-up</i>	56
Figura 30 – Comportamento do IQR do fator α , em função de η . Os dados passaram por extração de atributos, sem a presença de <i>pile-up</i>	58
Figura 31 – Comportamento do IQR do fator α , em função da energia. Os dados passaram por extração de atributos, sem a presença de <i>pile-up</i>	59
Figura 32 – Gráfico de resolução em função da energia na faixa de 40 a 50 GeV. Os dados passaram por extração de atributos, sem a presença de <i>pile-up</i>	60
Figura 33 – Comportamento do IQR do fator α , em função de η . Os dados passaram por extração de atributos, com a presença de <i>pile-up</i>	61
Figura 34 – Comportamento do IQR do fator α , em função da energia. Os dados passaram por extração de atributos, com a presença de <i>pile-up</i>	62
Figura 35 – Gráfico de resolução em função da energia na faixa de 40 a 50 GeV, considerando o efeito <i>pile-up</i>	63
Figura 36 – Comportamento do IQR do fator α , em função de η . Os dados passaram por pela extração de variáveis energéticas e assimétricas com a aplicação do logaritmo na soma das energias do calorímetro, sem a presença de <i>pile-up</i>	64
Figura 37 – Comportamento do IQR do fator α , em função da energia. Os dados passaram por extração de atributos, sem a presença de <i>pile-up</i>	65
Figura 38 – Gráfico de resolução em função da energia na faixa de 40 a 50 GeV. Os dados passaram por extração de atributos, sem a presença de <i>pile-up</i>	65
Figura 39 – Comportamento do IQR do fator α , em função de η . Os dados passaram por extração de atributos, com a presença de <i>pile-up</i>	67
Figura 40 – Comportamento do IQR do fator α , em função da energia. Os dados passaram por extração de atributos, com a presença de <i>pile-up</i>	68
Figura 41 – Gráfico de resolução em função da energia na faixa de 40 a 50 GeV, considerando o efeito <i>pile-up</i>	68
Figura 42 – Comportamento do IQR do fator α , em função de η , sem a presença de <i>pile-up</i>	70
Figura 43 – Comportamento do IQR do fator α , em função da energia , sem a presença de <i>pile-up</i>	71
Figura 44 – Gráfico de resolução em função da energia na faixa de 40 a 50 GeV , sem a presença de <i>pile-up</i>	72
Figura 45 – Comportamento do IQR do fator α , em função da η , com <i>pile-up</i> $< \mu >$ na faixa de 25 a 52.	74
Figura 46 – Comportamento do IQR do fator α , em função da energia, com <i>pile-up</i> $< \mu >$ na faixa de 25 a 52.	75

Figura 47 – Gráfico de resolução em função da energia na faixa de 40 a 50 GeV, considerando o efeito do <i>pile-up</i>	75
Figura 48 – Comportamento do IQR do fator α , em função de η . Os dados passaram por extração de atributos, sem a presença de <i>pile-up</i>	77
Figura 49 – Comportamento do IQR do fator α , em função da energia. Os dados passaram por extração de atributos, sem a presença de <i>pile-up</i>	78
Figura 50 – Gráfico de resolução em função da energia na faixa de 20 a 30 GeV. Os dados passaram por extração de atributos, sem a presença de <i>pile-up</i>	79
Figura 51 – Comportamento do IQR do fator α , em função de η . Os dados passaram por extração de atributos, com a presença de <i>pile-up</i>	80
Figura 52 – Comportamento do IQR do fator α , em função da energia. Os dados passaram por extração de atributos, com a presença de <i>pile-up</i>	81
Figura 53 – Gráfico de resolução em função da energia na faixa de 40 a 50 GeV, considerando o efeito <i>pile-up</i>	82
Figura 54 – Comportamento do IQR do fator α , em função da η , sem a presença de <i>pile-up</i>	87
Figura 55 – Comportamento do IQR do fator α , em função da η , sem a presença de <i>pile-up</i>	88
Figura 56 – Comportamento do IQR do fator α , em função da η , sem a presença de <i>pile-up</i>	89
Figura 57 – Comportamento do IQR do fator α , em função da η , sem a presença de <i>pile-up</i>	90

Lista de Tabelas

Tabela 1	– Quantidade de anéis calculados para cada camada do calorímetro do ATLAS.	29
Tabela 2	– <i>Quarter Rings</i> dispostos por camada no sistema de calorimetria do experimento ATLAS.	30
Tabela 3	– Métodos utilizados para a calibração do calorímetro.	40
Tabela 4	– Desempenho dos <i>Quarter Rings</i> em diferentes faixas de pseudorapidez	52
Tabela 5	– Desempenho dos <i>Quarter Rings</i> em diferentes faixas de energia	52
Tabela 6	– Ganho médio percentual do IQR para as configurações analisadas, em função de η , sem a presença de <i>pile-up</i>	53
Tabela 7	– Ganho médio percentual do IQR para as configurações analisadas, em função da energia, sem a presença de <i>pile-up</i>	53
Tabela 8	– Desempenho dos <i>Quarter Rings</i> em diferentes faixas de pseudorapidez	55
Tabela 9	– Ganho médio percentual do IQR para as configurações analisadas, em função de η , com a presença de <i>pile-up</i>	57
Tabela 10	– Ganho médio percentual do IQR para as configurações analisadas, em função da energia, com a presença de <i>pile-up</i>	57
Tabela 11	– Desempenho dos <i>Quarter Rings</i> em diferentes faixas de pseudorapidez	58
Tabela 12	– Desempenho dos <i>Quarter Rings</i> em diferentes faixas de energia	59
Tabela 13	– Ganho médio percentual do IQR para as configurações analisadas, em função de η , sem a presença de <i>pile-up</i>	60
Tabela 14	– Ganho médio percentual do IQR para as configurações analisadas, em função da energia, sem a presença de <i>pile-up</i>	60
Tabela 15	– Desempenho dos <i>Quarter Rings</i> em diferentes faixas de pseudorapidez	61
Tabela 16	– Ganho médio percentual do IQR para as configurações analisadas, em função de η , com a presença de <i>pile-up</i>	62
Tabela 17	– Ganho médio percentual do IQR para as configurações analisadas, em função da energia, com a presença de <i>pile-up</i>	63
Tabela 18	– Ganho médio percentual do IQR para as configurações analisadas, em função de η , sem a presença de <i>pile-up</i>	66
Tabela 19	– Ganho médio percentual do IQR para as configurações analisadas, em função da energia, sem a presença de <i>pile-up</i>	66
Tabela 20	– Ganho percentual do IQR para as configurações analisadas, em função de η , com a presença de <i>pile-up</i>	69
Tabela 21	– Ganho percentual do IQR para as configurações analisadas, em função da energia, com a presença de <i>pile-up</i>	69
Tabela 22	– Desempenho dos <i>Quarter Rings</i> em diferentes faixas de pseudorapidez	71
Tabela 23	– Desempenho dos <i>Quarter Rings</i> em diferentes faixas de energia	71
Tabela 24	– Ganho percentual do IQR para as configurações analisadas, em função de η , sem a presença de <i>pile-up</i>	72
Tabela 25	– Ganho percentual do IQR para as configurações analisadas, em função da energia, sem a presença de <i>pile-up</i>	72

Tabela 26 – Desempenho dos <i>Quarter Rings</i> em diferentes faixas de pseudorapidez	74
Tabela 27 – Desempenho dos <i>Quarter Rings</i> em diferentes faixas de energia	74
Tabela 28 – Ganho percentual do IQR para as configurações analisadas, em função de η , com a presença de <i>pile-up</i>	76
Tabela 29 – Ganho percentual do IQR para as configurações analisadas, em função da energia, com a presença de <i>pile-up</i>	76
Tabela 30 – Desempenho dos <i>Quarter Rings</i> em diferentes faixas de pseudorapidez	77
Tabela 31 – Desempenho dos <i>Quarter Rings</i> em diferentes faixas de energia	78
Tabela 32 – Ganho médio percentual do IQR para as configurações analisadas, em função de η , sem a presença de <i>pile-up</i>	79
Tabela 33 – Ganho médio percentual do IQR para as configurações analisadas, em função da energia, sem a presença de <i>pile-up</i>	79
Tabela 34 – Desempenho dos <i>Quarter Rings</i> em diferentes faixas de pseudorapidez	80
Tabela 35 – Desempenho dos <i>Quarter Rings</i> em diferentes faixas de energia	81
Tabela 36 – Ganho médio percentual do IQR para as configurações analisadas, em função de η , com a presença de <i>pile-up</i>	81
Tabela 37 – Ganho médio percentual do IQR para as configurações analisadas, em função da energia, com a presença de <i>pile-up</i>	81
Tabela 38 – Comparação do desempenho dos <i>Quarter Rings</i> em diferentes faixas de pseudorapidez, com e sem <i>pile-up</i>	83
Tabela 39 – Desempenho dos <i>Quarter Rings</i> em diferentes faixas de energia	83
Tabela 40 – Comparação do desempenho dos <i>Quarter Rings</i> em diferentes faixas de pseudorapidez, com e sem <i>pile-up</i>	84
Tabela 41 – Desempenho dos <i>Quarter Rings</i> em diferentes faixas de energia	84
Tabela 42 – Comparação do desempenho dos <i>Quarter Rings</i> em diferentes faixas de pseudorapidez, sem e com <i>pile-up</i>	85
Tabela 43 – Comparação do desempenho dos <i>Quarter Rings</i> em diferentes faixas de energia, sem e com <i>pile-up</i>	85
Tabela 44 – Comparação do desempenho dos <i>Quarter Rings</i> com redes neurais em diferentes faixas de pseudorapidez, com e sem <i>pile-up</i>	86
Tabela 45 – Comparação do desempenho dos <i>Quarter Rings</i> em diferentes faixas de energia, sem e com <i>pile-up</i>	86
Tabela 46 – Comparação de desempenho entre GBDT e Rede Neural em diferentes faixas de pseudorapidez	88
Tabela 47 – Comparação de desempenho entre GBDT e Rede Neural em diferentes faixas de energia	88
Tabela 48 – Comparação de desempenho entre GBDT e Rede Neural em diferentes faixas de pseudorapidez	89
Tabela 49 – Comparação de desempenho entre GBDT e Rede Neural em diferentes faixas de energia	90
Tabela 50 – Comparação do desempenho entre GBDT e Rede Neural nas diferentes faixas de pseudorapidez para os dois métodos de análise	91
Tabela 51 – Comparação do desempenho entre GBDT e Rede Neural nas diferentes faixas de energia para os dois métodos de análise	91

Listas de Nomenclaturas e Símbolos

α Fator de calibração

η Pseudorapidez

ϕ Ângulo azimutal

θ Ângulo polar

ALICE *A Large Ion Collider Experiment*

ATLAS *A Toroidal LHC Apparatus*

CERN Organização Europeia para a Pesquisa Nuclear

CMS *Compact Muon Solenoid*

CTP *Processador Central de Trigger*

E_T Energia transversa das partículas, em geral medida em GeV

E_{Truth} Energia simulada por Monte Carlo

ECAL Calorímetro eletromagnético

eV Elétron-volt

FastCalo *Fast Calorimeter Reconstruction*

FCal *Forward Calorimeter*

GBDT *Gradient Boosted Decision Tree*

HotCell Célula com a maior deposição de energia

HCAL Calorímetro hadrônico

HEC *Hadronic End-cap Calorimeter*

HLT *High Level Trigger*

IA Inteligência Artificial

ID Detector Interno

IP Ponto de Interação

LAr Argônio líquido

LHC *Large Hadron Collider*

LHCb *Large Hadron Collider beauty*

MLP *Multilayer Perceptron*

MP *Modelo Padrão*

MS *Muon Spectrometer*

PMTs *Tubos Fotomultiplicadores*

PS *Synchrotron*

PSB *Proton Synchrotron Booster*

QR *Quarter Rings*

RoI *Região de Interesse*

SPS *Super Proton Synchrotron*

T *Tesla*

TB *Terabyte*

TeV *Teraelétron-volt*

TileCal *Calorímetro de Telhas*

WWW *World Wide Web*

Agradecimentos

Agradeço a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo suporte financeiro ao desenvolvimento desta pesquisa, por meio da concessão de bolsa de estudos durante o período do mestrado.

Resumo

O detector ATLAS (*A Toroidal LHC ApparatuS*), parte do *Large Hadron Collider* (LHC) do CERN, é um dos maiores e mais complexos experimentos em física de partículas já construídos. Ele é composto por diversos subsistemas, incluindo o sistema de calorimetria, formado por detectores finamente segmentados, responsáveis por medir a energia e a posição das partículas. O ATLAS foi projetado para detectar e classificar partículas subatômicas produzidas nas colisões de alta energia. Um dos desafios enfrentados no experimento é a calibração da energia das partículas detectadas, essencial para garantir a acurácia das análises realizadas. Este trabalho investigou a calibração de energia do calorímetro do ATLAS, utilizando regressores baseados em *Gradient Boosted Decision Tree* (GBDT) e Redes Neurais *Feedforward* do tipo *Multilayer Perceptron* (MLP), que receberam como entrada estruturas chamadas *Standard Rings* e *Quarter Rings*. Essas estruturas são construídas a partir das informações do calorímetro, organizadas de forma a preservar características espaciais dos chuveiros de partículas. A partir da definição de uma região de interesse ao redor do ponto de interação da partícula, os sinais dos sensores são organizados em anéis concêntricos. Os *Standard Rings* codificam a energia das células contidas em cada anel para cada camada do calorímetro, enquanto os *Quarter Rings* são obtidos pela divisão de cada *Standard Rings* em quatro partes, com exceção do primeiro anel (*HotCell*), permitindo capturar as assimetrias no perfil de deposição de energia. Um dos desafios enfrentados na calibração do calorímetro é lidar com as variações na resposta do detector, que podem ser significativas em função da energia transversa das partículas (E_T) e da pseudorapidez (η), um parâmetro geométrico que descreve a posição da partícula em relação ao eixo do feixe. Essas variações tornam-se particularmente críticas em baixos valores de energia, nos quais a identificação de elétrons é mais desafiadora devido ao perfil característico de deposição de energia. O fator de calibração (α), definido como a razão entre a energia simulada por Monte Carlo e a energia estimada no *High Level Trigger* (HLT), é aplicado à energia bruta fornecida pelo algoritmo *FastCalo* com o objetivo de corrigir distorções decorrentes de perdas no detector. Outro aspecto considerado neste estudo é o impacto do *pile-up*, múltiplas interações simultâneas em uma mesma colisão, que afeta a identificação e a reconstrução precisa das partículas. Por isso, a análise foi conduzida em diferentes cenários, com e sem a presença de *pile-up*, e utilizando diferentes estratégias de entrada: dados brutos e pela extração de variáveis energéticas e assimétricas. Os resultados indicam que, embora o *pile-up* reduza parcialmente a eficácia da calibração, especialmente nas estimativas em função da energia, os modelos testados mantêm desempenho robusto. Os *Quarter Rings* se destacaram por apresentar ganhos mais expressivos em determinadas faixas de pseudorapidez, enquanto a aplicação da extração de atributos contribuiu para a melhoria das estimativas, embora algumas configurações tenham se mostrado mais sensíveis a ambientes experimentais complexos. A utilização dos *Quarter Rings* proporcionou uma melhora de até 18,08% na calibração em relação à pseudorapidez e de até 15,2% em relação à energia, demonstrando vantagem em comparação ao cenário sem calibração, e desempenho semelhante ao obtido com os *Standard Rings*. Esses resultados reforçam a viabilidade do uso de estruturas espacialmente refinadas, como os *Quarter Rings*, associadas a modelos de aprendizado de máquina para aprimorar a calibração do calorímetro do ATLAS, mesmo em condições adversas como a presença de *pile-up*. A abordagem proposta oferece uma alternativa promissora para futuras melhorias nos sistemas de reconstrução rápida e análise de eventos no experimento.

Abstract

The ATLAS detector (A Toroidal LHC Apparatus), part of the Large Hadron Collider (LHC) at CERN, is one of the largest and most complex particle physics experiments ever built. It is composed of several subsystems, including the calorimetry system, which consists of finely segmented detectors responsible for measuring the energy and position of particles. ATLAS was designed to detect and classify subatomic particles produced in high-energy collisions. One of the challenges faced in the experiment is the calibration of the energy of the detected particles, which is essential to ensure the accuracy of the analyses performed. This study investigated the energy calibration of the ATLAS calorimeter using regressors based on Gradient Boosted Decision Trees (GBDT) and feedforward neural networks of the Multilayer Perceptron (MLP) type, which received as input structures called Standard Rings and Quarter Rings. These structures are built from calorimeter information and organized in a way that preserves the spatial characteristics of particle showers. From the definition of a region of interest around the particle's interaction point, the signals from the sensors are arranged in concentric rings. The Standard Rings encode the energy of the cells contained in each ring for each calorimeter layer, while the Quarter Rings are obtained by dividing each Standard Ring into four parts — except for the first ring (HotCell) — allowing the capture of asymmetries in the energy deposition profile. One of the main challenges in calorimeter calibration is dealing with variations in the detector response, which can be significant depending on the particles' transverse energy (E_T) and pseudorapidity (η), a geometric parameter that describes the particle's position relative to the beam axis. These variations become particularly critical at low energy values, where electron identification is more difficult due to the characteristic energy deposition profile. The calibration factor (α), defined as the ratio between the Monte Carlo simulated energy and the energy estimated by the High Level Trigger (HLT), is applied to the raw energy provided by the FastCalo algorithm in order to correct distortions resulting from energy losses in the detector. Another aspect considered in this study is the impact of pile-up — multiple simultaneous interactions in a single collision — which affects the precise identification and reconstruction of particles. Therefore, the analysis was conducted under different scenarios, with and without the presence of pile-up, and using different input strategies: raw data and data derived from the extraction of energetic and asymmetric variables. The results indicate that although pile-up partially reduces calibration effectiveness — especially in energy-based estimates — the tested models maintained robust performance. The Quarter Rings stood out by showing more significant gains in certain pseudorapidity regions, while the application of feature extraction contributed to improving the estimates, although some configurations proved more sensitive to complex experimental environments. The use of Quarter Rings led to improvements of up to 18.08% in pseudorapidity-based calibration and up to 15.2% in energy-based calibration, showing a clear advantage over the uncalibrated scenario and performance similar to that obtained with Standard Rings. These results reinforce the feasibility of using spatially refined structures, such as the Quarter Rings, combined with machine learning models to improve ATLAS calorimeter calibration, even under adverse conditions such as the presence of pile-up. The proposed approach offers a promising alternative for future improvements in fast reconstruction systems and event analysis in the experiment.

Sumário

1	INTRODUÇÃO	14
1.1	Objetivos	16
1.1.1	Objetivo Geral	16
1.1.2	Objetivos Específico	16
2	VISÃO GERAL SOBRE O EXPERIMENTO A TOROIDAL LHC APPARATUS DO LARGE HADRON COLLIDER	17
2.1	<i>Large Hadron Collider</i>	17
2.2	O experimento <i>A Toroidal LHC Apparatus</i>	19
2.2.1	Calorímetros do Atlas	22
2.2.1.1	Calorímetro Eletromagnético	24
2.2.1.2	Calorímetro Hadrônico	26
2.3	Algoritmo <i>NeuralRinger</i>	27
2.4	<i>Quarter Rings</i>	29
2.5	Seleção online (<i>trigger</i>) de elétrons no experimento ATLAS	30
3	CALIBRAÇÃO DE ENERGIA USANDO APRENDIZADO DE MÁQUINA	33
4	METODOLOGIA	39
5	RESULTADOS	46
5.1	Resultados da GBDT	51
5.1.1	Análise pelo Método dos Dados Brutos sem a Presença de <i>Pile-Up</i>	51
5.1.2	Análise pelo Método dos Dados Brutos com a Presença de <i>Pile-Up</i>	55
5.1.3	Análise pelo Método da Extração de Variáveis Energéticas e Assimétricas sem a Presença de <i>Pile-Up</i>	58
5.1.4	Análise pelo Método da Extração de Variáveis Energéticas e Assimétricas com a Presença de <i>Pile-Up</i>	61
5.1.5	Análise pelo Método da Extração de Variáveis Energéticas e Assimétricas com a Aplicação do Logaritmo na Soma das Energias do Calorímetro sem a Presença de <i>Pile-Up</i>	64
5.1.6	Análise pelo Método da Extração de Variáveis Energéticas e Assimétricas com a Aplicação do Logaritmo na Soma das Energias do Calorímetro com a Presença de <i>Pile-Up</i>	67
5.2	Resultados da Rede Neural <i>Feedforward</i>	70
5.2.1	Análise pelo Método dos Dados Brutos sem a Presença de <i>Pile-Up</i>	70
5.2.2	Análise pelo Método dos Dados Brutos com a Presença de <i>Pile-Up</i>	74
5.2.3	Análise pelo Método da Extração de Variáveis Energéticas e Assimétricas sem a Presença de <i>Pile-Up</i>	77

5.2.4	Análise pelo Método da Extração de Variáveis Energéticas e Assimétricas com a Presença de <i>Pile-Up</i>	80
5.3	Comparação das Abordagens de Calibração	83
5.3.1	Comparação entre os Resultados da GBDT com e sem <i>Pile-Up</i> , com a Utilização do Método dos Dados Brutos	83
5.3.2	Comparação entre os Resultados da GBDT com e sem <i>Pile-Up</i> , pelo Método da Extração de Variáveis Energéticas e Assimétricas	84
5.3.3	Comparação entre os Resultados da GBDT com e sem <i>Pile-Up</i> , com a aplicação do logarítmico na soma das energias do calorímetro	85
5.3.4	Comparação entre os Resultados da Rede Neural com e sem <i>Pile-Up</i> , com o Método dos Dados Brutos	85
5.3.5	Comparação entre os Resultados da Rede Neural com e sem <i>Pile-Up</i> , Com o Método da Extração de Variáveis Energéticas e Assimétricas	86
5.4	Comparativo de Resultados entre GBDT e a Rede Neural	87
5.4.1	Análise pelo Método dos Dados Brutos sem a Presença de <i>Pile-Up</i>	87
5.4.2	Análise pelo Método da Extração de Variáveis Energéticas e Assimétricas sem a Presença de <i>Pile-Up</i>	89
6	CONSIDERAÇÕES FINAIS	92
	BIBLIOGRAFIA	94
	ANEXOS	97
	ANEXO A – PUBLICATIONS	98

1 Introdução

A Organização Europeia para a Pesquisa Nuclear (CERN), localizada na fronteira entre a França e a Suíça, é atualmente um dos mais importantes centros de pesquisa científica do mundo e o maior laboratório dedicado à física de altas energias. Seu principal objetivo é investigar a estrutura fundamental da matéria e as forças que governam o comportamento das partículas subatômicas [1, 2].

Ao longo de sua história, o CERN acumulou realizações significativas, como a produção controlada de antimatéria, um marco em experimentos científicos. Em 1983, a descoberta dos bósons W e Z foi fundamental para consolidar o entendimento das forças que regem as partículas elementares [3].

O CERN tem um papel importante na história da Internet, sendo o local onde a *World Wide Web* (WWW) foi criada em 1989, revolucionando a comunicação global. Em 2012, o CERN confirmou a existência do bóson de Higgs, um avanço essencial para a compreensão da origem da massa das partículas elementares. Além disso, o *Large Hadron Collider* (LHC), inaugurado em 2008, é o maior e mais poderoso acelerador de partículas do mundo [4].

A física de partículas é o campo responsável pelo estudo das partículas elementares e das interações fundamentais que atuam no universo em suas escalas mais elementares. A descrição mais abrangente atualmente disponível é fornecida pelo Modelo Padrão (MP), uma teoria desenvolvida ao longo dos últimos 60 anos. Esse modelo foi submetido a rigorosos testes experimentais e teve suas previsões amplamente confirmadas [5].

A ideia de que a matéria é composta de átomos surgiu no século V a.C, na Grécia Antiga, com a proposta de Demócrito de que os átomos seriam partículas indivisíveis. No entanto, foi no século XIX e início do século XX que descobertas fundamentais sobre eletricidade, magnetismo e radiação lançaram as bases para o entendimento moderno da estrutura atômica. O modelo atômico de Rutherford, desenvolvido no início do século XX, revolucionou essa visão ao descrever o átomo como um núcleo central denso e positivo, em torno do qual os elétrons orbitam [6].

Em 1932, a descoberta do nêutron por Chadwick foi crucial para completar o modelo do núcleo atômico, permitindo uma compreensão mais precisa da estrutura e estabilidade dos átomos. Nas décadas de 1950 e 1960, a identificação de novas partículas subatômicas levou ao desenvolvimento do Modelo de Partículas Elementares, que foi consolidado na década de 1970 com o estabelecimento do Modelo Padrão, conforme mostrado na Figura 1. O qual unificou interações fundamentais e descreveu as partículas conhecidas [7].

O Modelo Padrão, Figura 1, é uma estrutura teórica que classifica e descreve as partículas fundamentais da matéria, como quarks, léptons e bósons de calibre, e suas interações por meio das forças fortes, fracas e eletromagnéticas. No total, são consideradas 17 partículas fundamentais, divididas em: bósons, quarks e léptons, que compõem a matéria e as interações existentes no universo [7].

A última grande conquista do Modelo Padrão ocorreu em 2012, com a descoberta do bóson de Higgs pelo experimento *A Toroidal LHC ApparatuS* (ATLAS) e *Compact Muon Solenoid* (CMS) do *Large Hadron Collider* (LHC). Ao longo dessas seis décadas, a física de partículas tem se destacado por avanços

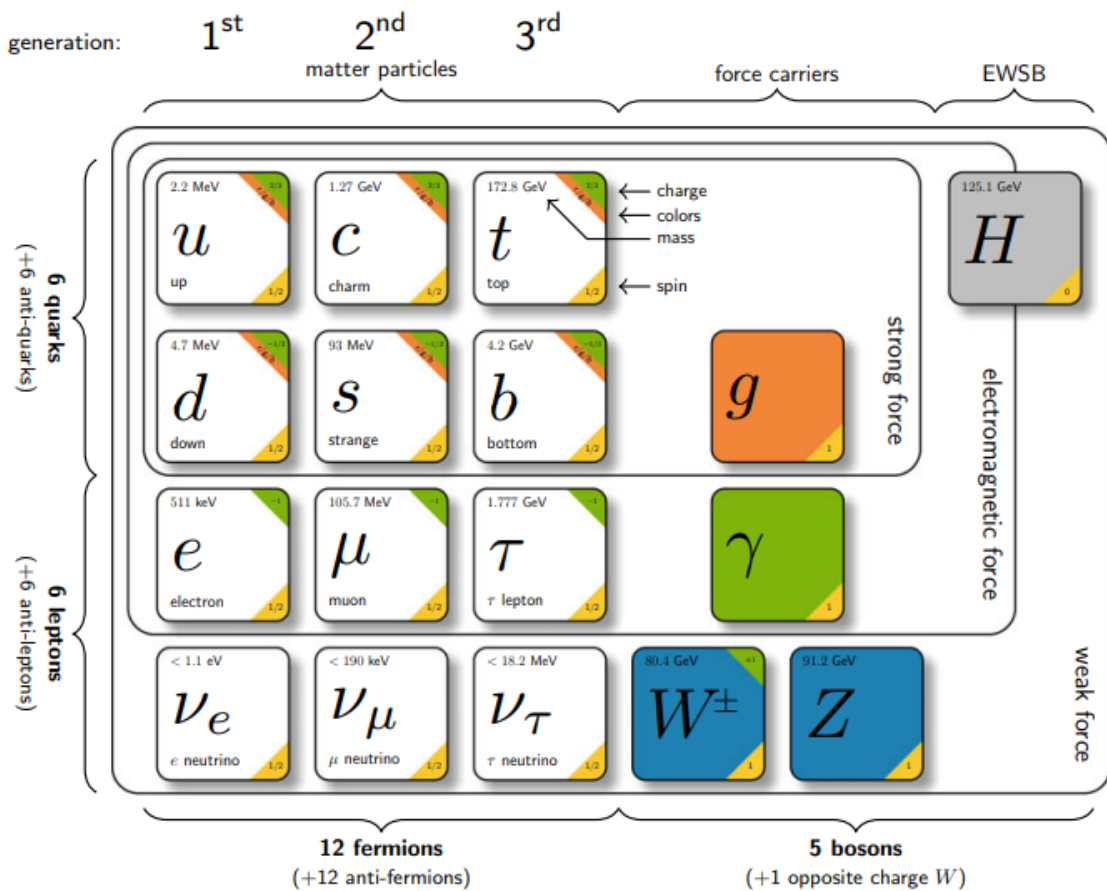


Figura 1 – Representação do Modelo Padrão de Partículas, dividido em partículas de matéria e portadores de força. [7]

notáveis, consolidando seu papel na busca por um entendimento mais profundo da matéria e das forças fundamentais que moldam o universo [7].

Um dos principais experimentos conduzidos no CERN é o ATLAS, que conta com um sistema sofisticado de detecção composto por um detector de traços, uma câmara de múons e calorímetros eletromagnético e hadrônico [8]. A análise das partículas geradas nas colisões próton-próton realizadas pelo LHC permite investigações aprofundadas no campo da física de altas energias. Dentre os componentes do experimento, o sistema de calorimetria do ATLAS tem papel fundamental, pois possibilita a medição precisa da energia e da posição de interação das partículas [9].

A calibração é um elemento importante na instrumentação científica, especialmente em ambientes como o CERN, onde um dos principais responsáveis por uma medição experimental bem-sucedida são os sistemas de aceleradores e de *trigger*, e as perdas nessa etapa são irreversíveis [10]. No caso do ATLAS, o processo de calibração busca corrigir fatores de erro nas medições, sendo crucial para garantir resultados confiáveis e interpretar corretamente os eventos de colisão [11].

A incorporação de técnicas de aprendizado de máquina, uma subárea da Inteligência Artificial (IA), tem sido importante nos experimentos do CERN [11, 12]. Essas técnicas não apenas contribuem significativamente para a análise e interpretação dos dados gerados, como também estão sendo aplicadas em problemas complexos da física de partículas, como no experimento ATLAS.

Este trabalho compara duas técnicas de aprendizado de máquina distintas, a técnica *Gradient*

Boosted Decision Tree (GBDT) e a rede neural do Tipo *Feedforward Multilayer Perceptron* (MLP) que foram implementadas com o objetivo de avaliar seus desempenhos quando comparadas ao método sem calibração.

1.1 Objetivos

1.1.1 Objetivo Geral

O presente trabalho teve como objetivo geral propor uma estratégia de calibração para medições de energia no experimento ATLAS, utilizando informações sobre assimetrias nos perfis de deposição de energia dos calorímetros. Foram empregados regressores baseados em *Gradient Boosted Decision Trees* (GBDT) e Redes Neurais para explorar essas assimetrias, visando otimizar a calibração e aprimorar a precisão, eficiência e robustez das medições.

1.1.2 Objetivos Específico

Este estudo visou avaliar o desempenho e a capacidade de generalização das abordagens de aprendizado de máquina utilizadas, tendo como objetivos específicos:

1. A avaliação de diferentes configurações de entrada, comparando dois conjuntos de dados principais: *Standard Ring* e *Quarter Rings*. O foco foi neste no último conjunto, dada sua capacidade de descrever assimetrias nos perfis laterais e longitudinais dos chuveiros eletromagnéticos;
2. A implementação e validação do modelo baseado em GBDT e em Rede Neural [11], [12], [13], [14].
3. A realização de comparação, em nível de simulação, dos resultados obtidos com os dados calibrados pelas abordagens propostas e os dados não calibrados, analisando a precisão e a eficiência de cada método.
4. A verificação se a inclusão das informações sobre assimetrias pode aprimorar a estimativa de energia no processo de calibração.
5. A avaliação do efeito do impacto do efeito do *pile-up* na calibração.

2 Visão Geral Sobre o Experimento *A Toroidal LHC ApparatuS* do *Large Hadron Collider*

A Organização Europeia para a Pesquisa Nuclear (CERN) é uma prestigiada instituição internacional fundada em 1954, localizada em Meyrin, na região metropolitana de Genebra. Com a colaboração de 24 estados membros [15], o CERN se destaca como um dos maiores centros de pesquisa do mundo, dedicado a explorar as partículas elementares e as forças com as quais interagem e ampliar o conhecimento sobre as leis que regem a natureza.

Sua missão é desvendar os segredos da composição e do funcionamento do universo por meio de pesquisas em física fundamental, utilizando uma infraestrutura única de aceleradores de partículas. Essas instalações não apenas impulsionam o conhecimento humano, mas também são administradas de maneira ambientalmente responsável e sustentável [16].

Ao longo de sua história, o CERN acumulou realizações significativas. Desde a produção controlada de antimatéria até a descoberta dos bósons W e Z em 1983, esses marcos foram fundamentais para consolidar nosso entendimento das forças que regem as partículas elementares [17]. Além disso, o CERN desempenhou um papel importante na história da Internet ao ser o local onde a *World Wide Web* (WWW) foi concebida em 1989, transformando radicalmente a comunicação global. Em 2012, a confirmação da existência do bóson de Higgs pelo CERN representou um avanço essencial na compreensão da origem da massa das partículas elementares [4].

O *Large Hadron Collider* (LHC), inaugurado em 2008, utiliza uma tecnologia avançada para colidir feixes de partículas em altíssimas energias. O LHC maximiza a energia disponível a partir da precisão extrema no direcionamento dos feixes. Atualmente é a maior instalação de pesquisa de física de partículas, consolidando o CERN como referência global na ciência [7].

2.1 *Large Hadron Collider*

O *Large Hadron Collider* (LHC) é um acelerador e colisor de partículas localizado no CERN. Instalado em um túnel aproximadamente circular de 26,7 km de extensão, localizado entre 45 e 170 metros abaixo do solo, o LHC foi projetado para colidir prótons com prótons (pp) a uma energia de pico de 14 TeV no centro de massa. Além disso, íons de chumbo podem ser acelerados e colididos tanto com prótons quanto com outros íons de chumbo. O projeto do LHC tem dois objetivos principais [7]:

1. Operar na mais alta energia de centro de massa tecnicamente possível, a fim de possibilitar a produção de partículas com massas até a escala do TeV . Na física de partículas, massa e energia são grandezas equivalentes, conforme descrito pela equação de Einstein $E = mc^2$. Como essa relação permite converter diretamente entre massa e energia, é comum expressar a massa das partículas em unidades de energia, como o elétron-volt (eV) , que representa a energia adquirida por um elétron ao atravessar uma diferença de potencial de um volt. Um TeV equivale a 10^{12} eV.

Para alcançar energias tão altas, o LHC utiliza prótons em vez de elétrons. Isso se deve ao fato de que partículas carregadas, ao se moverem em trajetórias curvas dentro de aceleradores circulares, emitem energia na forma de radiação eletromagnética — um fenômeno conhecido como radiação síncrotron. A quantidade de energia perdida por radiação síncrotron depende fortemente da massa da partícula: partículas mais leves, como os elétrons, perdem muito mais energia do que partículas mais pesadas, como os prótons. Dessa forma, o uso de prótons reduz significativamente as perdas por radiação, permitindo alcançar energias muito maiores [18], [17].

2. Operar com uma luminosidade instantânea suficiente para observar processos raros em um tempo de execução viável. Por esse motivo, prótons são colididos com prótons em vez de antiprótons, devido às dificuldades associadas à criação de um feixe de antiprótons de alta intensidade [7].

O LHC é composto por cinco aceleradores distintos e diversos equipamentos auxiliares, Figura 2. Os prótons são obtidos a partir de hidrogênio comum, removendo-se os elétrons através da fonte *Duoplasmatron*, que fornece prótons com uma energia de 100 mil elétron-volts (1×10^5 eV), equivalente a cerca de 1,5% da velocidade da luz. Esses prótons são então acelerados através de uma cadeia de pré-aceleradores antes de serem injetados no LHC [19].

O primeiro acelerador que um próton passa é o *Linac 2*, um acelerador linear de 33 metros de comprimento que aumenta a energia do próton para 50 milhões de elétron-volts. Ao sair do *Linac 2*, o próton possui cerca de um milionésimo da energia que terá ao final do processo de aceleração. Após o *Linac 2*, o próton é direcionado ao *Proton Synchrotron Booster (PSB)*, um acelerador circular com circunferência de 157 metros, onde a energia do próton é aumentada para 1,4 bilhão de elétron-volts [19].

O próximo acelerador é o *Proton Synchrotron (PS)*, que antes do LHC era o maior acelerador de energia do mundo. Com uma circunferência de 628 metros, o PS aumenta a energia do próton para 25 bilhões de elétron-volts. O *Super Proton Synchrotron (SPS)*, com mais de 7 km de circunferência, é o penúltimo acelerador, aumentando a energia do próton para 450 bilhões de elétron-volts. Neste acelerador, as partículas W e Z foram descobertas [19].

O último estágio é o próprio LHC, que recebe os prótons do SPS e os acelera a 7 trilhões de elétron-volts, atingindo 100% da energia projetada e fazendo com que a velocidade do próton chegue a 99,9999991% da velocidade da luz. Essa velocidade extrema é uma consequência direta da teoria da relatividade especial de Einstein [19].

O LHC tem dois feixes de partículas contra-rotativas que permitem colisões frontais - como cada feixe carrega 7 TeV, as colisões frontais no LHC têm 14 GeV de energia disponível, maximizando o nível energético necessário para revelar novos fenômenos físicos [20].

Os ímãs de curvatura operam com um campo magnético de 8,3 Tesla, que é cerca de 170 mil vezes mais poderoso que o campo magnético da Terra. Este campo é gerado por 11.800 amperes de corrente elétrica nos ímãs, cuja potência é equivalente a cerca de 120 milhões de watts no pico da demanda [19].

Os feixes de prótons circulam em tubos de vácuo no LHC, que é dividido em oito setores de arco e oito seções retas. Nos setores de arco, ímãs dipolares curvam os prótons para formar um caminho fechado, enquanto nas seções retas ocorrem as colisões dos prótons e abrigam cavidades de radiofrequência supercondutoras que aceleram os feixes [21].

Os feixes de prótons circulam no LHC pouco mais de dez mil vezes por segundo, resultando em aproximadamente 800 milhões de colisões por segundo em cada detector. O LHC também pode acelerar íons pesados, sendo otimizado para núcleos de chumbo. A energia armazenada nos feixes é cuidadosamente controlada para evitar danos aos detectores de partículas, sendo desviada para absorvedores de grafite quando necessário [21].

O LHC conta com quatro detectores principais, Figura 2, que registram os resultados das colisões: ATLAS e CMS, ambos de uso geral; *Large Hadron Collider beauty* (LHCb), um espectrômetro frontal para medir decaimentos de hádrons de sabor pesado; e o *A Large Ion Collider Experiment* (ALICE), otimizado para estudar colisões de íons pesados e explorar o plasma de quarks e glúons [7].

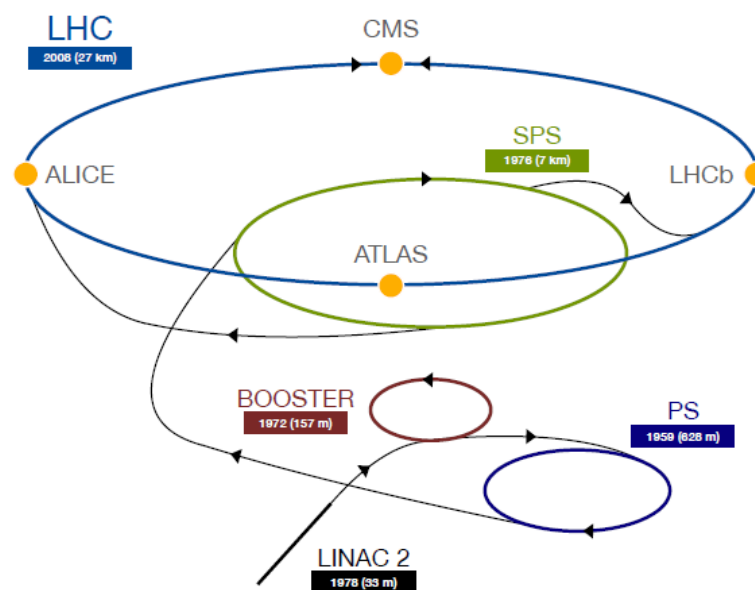


Figura 2 – Representação da cadeia de injeção do LHC. Os prótons são acelerados em etapas por quatro aceleradores distintos antes de serem injetados no LHC. [22]

2.2 O experimento A Toroidal LHC ApparatuS

O detector *A Toroidal LHC ApparatuS* (ATLAS) é um experimento de uso geral que registra as colisões do LHC, com 45 metros de comprimento, 22,5 metros de largura e com cerca de 7.000 toneladas. Ele consiste em uma região cilíndrica central onde subdetectores são colocados em camadas ao redor do ponto de interação para medir as características das partículas criadas nas colisões [7]. Em ambas as extremidades do barril, há estruturas em camadas chamadas *end-caps*, compostas por subdetectores que fecham o detector lateralmente. Dessa forma, é alcançada uma cobertura angular sólida próxima de 4π , o que maximiza a aceitação do detector e permite reconstruir os estados finais das interações de forma tão completa quanto possível [7]. Uma ilustração em corte do detector ATLAS com seus vários subdetectores é mostrada na Figura 3.

A configuração do sistema de ímãs consiste em um fino solenóide supercondutor ao redor da cavidade do detector interno, com três grandes toroides supercondutores (um no barril central e dois nas tampas laterais), dispostos com simetria azimutal de oito setores ao redor dos calorímetros. Os poderosos




Figura 3 – O experimento ATLAS e seus subsistemas. [23]

ímãs curvam as trajetórias das partículas carregadas, e a medição dessas trajetórias permite determinar seus momentos [23].

O experimento ATLAS utiliza um sistema de coordenadas ilustrado na Figura 4, cuja origem está localizada no ponto de interação (IP). O eixo z é definido paralelo à direção do feixe de partículas. O eixo x aponta do ponto de interação para o centro da circunferência do LHC, enquanto o eixo y é perpendicular ao eixo x, com sentido positivo para cima [24], [25].

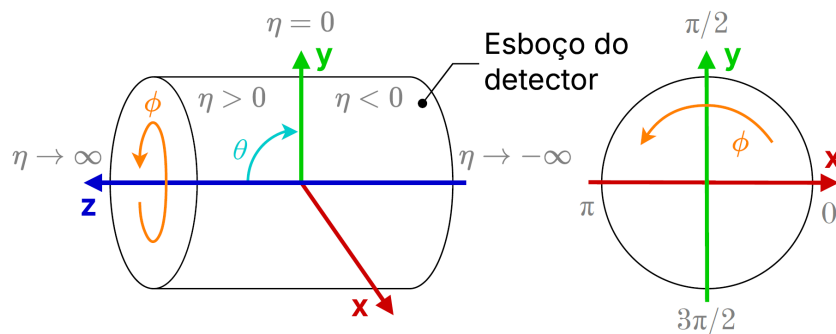


Figura 4 – Sistema de coordenadas do calorímetro ATLAS. Adaptado da tese de Simas Filho [25], com modificações feitas por André Paiva.

Esse sistema de coordenadas serve como referência comum para a identificação e a reconstrução das trajetórias e interações das partículas nos diversos subsistemas do detector. Para a descrição das posições no plano transversal, utilizam-se coordenadas cilíndricas (r, ϕ) , onde o ângulo azimutal (ϕ) é medido em torno do eixo do feixe x no plano xy , e o ângulo polar (θ) é o ângulo em relação ao eixo z . A pseudorapidez η é definida em função do ângulo polar θ pela expressão [26]:

$$\eta = -\ln \tan \left(\frac{\theta}{2} \right) \tag{2.1}$$

Essa referência espacial é essencial para o funcionamento dos três sistemas principais de detectores do ATLAS: o Detector Interno (ID), responsável por medir as trajetórias das partículas carregadas; o

Sistema de Calorímetros, que mede a energia das partículas ao absorvê-las; e o Espectrômetro de Múons, que detecta partículas do tipo múon, geralmente localizadas nas regiões mais externas do detector [27].

O Detector Interno (ID) do ATLAS, Figura 5, é um sistema de rastreamento de alta precisão que envolve o tubo de feixe e opera imerso em um campo magnético axial de 2 T, gerado por um solenóide supercondutor [7]. Ele é composto por três subdetectores principais: o Detector de Pixels, o Rastreador de Semicondutores (SCT) e o Rastreador de Radiação de Transição (TRT). Esses subdetectores detectam depósitos localizados de energia (*hits*) de partículas carregadas, permitindo a reconstrução de suas trajetórias curvadas (*tracks*). Essas trajetórias fornecem informações sobre o sinal da carga elétrica das partículas, seu momento e a localização dos vértices primários de interação, bem como dos vértices secundários e terciários oriundos de decaimentos de hádrons pesados [28].




Figura 5 – Ilustração em corte do detector interno ATLAS. [28]

Essa configuração é cercada por um calorímetro eletromagnético e um calorímetro hadrônico, que medem a energia das partículas que produzem chuviscos por meio da interação eletromagnética ou da força forte, respectivamente [7].

Na parte mais externa do detector ATLAS encontra-se o *Muon Spectrometer (MS)*, um sistema dedicado ao rastreamento de múons, cujas trajetórias são desviadas por um conjunto de ímãs toroidais [7].

O detector ATLAS identifica as partículas a partir das assinaturas que elas deixam ao atravessá-lo. A Figura 6 ilustra essas assinaturas e mostra como elas são usadas para a identificação. Por exemplo, elétrons, por serem partículas carregadas, deixam sinais no ID, o que possibilita a determinação de seu momento e carga. Ao atingir o calorímetro eletromagnético, eles geram uma cascata de partículas proporcional à sua energia total, sendo quase totalmente absorvidos ali, sem deixar rastros no calorímetro hadrônico ou no espectrômetro de múons [29].

Os fótons apresentam assinaturas no calorímetro semelhantes às dos elétrons, mas por não possuírem carga elétrica, atravessam o ID sem deixar rastros nem sofrer desvios. Já os prótons, que são partículas carregadas positivamente, deixam trilhas curvas no ID, assim como os elétrons. No entanto, por serem hádrons, iniciam sua cascata de partículas mais tarde, depositando a maior parte da energia no calorímetro hadrônico, responsável por medir a energia de hádrons. Os nêutrons, por sua vez, apresentam




Figura 6 – Ilustração das assinaturas que as partículas deixam ao atravessar o detector ATLAS. [29]

respostas calorimétricas parecidas com as dos prótons, mas como não têm carga elétrica, também não deixam sinais no ID [7].

Múons deixam sinais no ID e, por serem minimamente ionizantes — ou seja, ionizam o material apenas levemente ao atravessá-lo —, resultam em depósitos mínimos de energia e não produzem um chuveiro de partículas. Como consequência, são as únicas partículas que também deixam sinais no Espectrômetro de Múons. Neutrinos, por sua vez, atravessam o detector ATLAS sem deixar qualquer traço, sendo sua presença inferida indiretamente por meio do desequilíbrio de momento no plano transversal [30].

2.2.1 Calorímetros do Atlas

A calorimetria desempenha um papel importante na física de partículas. Inicialmente desenvolvida para o estudo de raios cósmicos, essa técnica foi aperfeiçoada para atender às exigências dos experimentos em aceleradores de partículas.

Os calorímetros podem ser classificados conforme sua técnica de construção. Os calorímetros de amostragem consistem em camadas alternadas de um material absorvedor — que absorve a energia da partícula — e um meio ativo, que gera o sinal detectável. Esses calorímetros são especialmente eficazes para detectar partículas de alta energia e são sensíveis também a partículas neutras, o que os torna úteis

para identificar diferentes tipos de partículas e medir a energia faltante. Em contraste, os calorímetros homogêneos são construídos com um único tipo de material que realiza tanto a absorção de energia quanto a geração do sinal [7].

A principal função dos calorímetros é absorver completamente a energia das partículas incidentes e convertê-la em uma quantidade mensurável. Quando uma partícula carregada interage com a parte ativa do calorímetro, a energia depositada pode ser detectada na forma de carga elétrica ou luz, permitindo a medição precisa da energia da partícula [7].

O sistema de calorímetros do experimento ATLAS, ilustrado na Figura 7, é composto por um calorímetro eletromagnético (ECAL) e um calorímetro hadrônico (HCAL) [21]. O ECAL é projetado principalmente para medir elétrons e fótons com base em suas interações eletromagnéticas, enquanto o HCAL mede hádrons, que interagem tanto pela força forte quanto pela força eletromagnética [31].

Ambos os calorímetros são simétricos em relação ao eixo do feixe e cobrem a região de pseudo-rapidez $|\eta| < 4,9$. Eles são segmentados para fornecer informações detalhadas na reconstrução de elétrons, fótons, jatos e na medição da energia transversal faltante. Utilizam a técnica de amostragem, com múltiplas camadas alternadas de material de detecção ativa e absorvedor passivo de alta densidade. A energia total das partículas é então extrapolada a partir dos sinais gerados nas camadas ativas. A combinação entre ECAL e HCAL proporciona capacidade de contenção suficiente para absorver completamente o chuveiro de partículas, evitando que estas atinjam o Espectrômetro de Múons [7].

Esses calorímetros estão distribuídos em três criostatos: um para o calorímetro eletromagnético do barril e dois para os calorímetros localizados nas tampas finais ("end-caps"). Cada criostato das tampas contém um ECAL, um calorímetro hadrônico posicionado logo atrás do ECAL e um *Forward Calorimeter* (FCal), projetado para cobrir a região mais próxima ao feixe. Todos esses calorímetros utilizam Argônio líquido (LAr) como meio ativo, devido à sua linearidade de resposta, estabilidade operacional e resistência à radiação [9].




Figura 7 – Ilustração em corte do sistema calorímetro ATLAS. [32]

Localizados logo após o solenóide, os calorímetros formam a camada seguinte do detector e absorvem a maior parte das partículas produzidas nas colisões do LHC, medindo sua energia e posição de

impacto geométrica [20].

Os calorímetros hadrônicos do ATLAS incluem o Calorímetro de Telhas (TileCal), o *Hadronic End-cap Calorimeter* (HEC) e o *Forward Calorimeter* (FCal). Esses dispositivos empregam materiais ativos e passivos otimizados para suportar níveis elevados de radiação e operar eficientemente em uma ampla faixa de pseudorapidez [33].

Em regiões de pseudorapidez mais elevada, como aquelas encontradas em experimentos de física de partículas, onde maior resistência à radiação é necessária, os calorímetros precisam ser projetados para suportar a radiação de forma eficiente, garantindo que as medições de energia sejam precisas e confiáveis [34].

Diferentemente dos espectrômetros magnéticos, os calorímetros são sensíveis tanto a partículas carregadas quanto neutras, permitindo, por exemplo, a detecção indireta de neutrinos por meio da medição da energia transversal faltante. Além disso, são capazes de estimar a posição e a direção das partículas, identificar diferentes espécies e medir seu tempo de chegada [7].

2.2.1.1 Calorímetro Eletromagnético

O Calorímetro Eletromagnético (ECAL) utiliza argônio líquido (LAr) como meio ativo, combinado com eletrodos de Kapton e placas de chumbo como material absorvedor. Localizado no barril, imediatamente atrás do solenóide supercondutor, o ECAL é formado por dois cilindros coaxiais separados por uma pequena lacuna em $z = 0$, que cobrem a região até $|\eta| < 1,475$. Cada cilindro possui aproximadamente 3,2 metros de comprimento, raio interno de 1,4 metros e externo de 2 metros, permitindo uma cobertura completa em ϕ com simetria azimutal [9].

O ECAL é dividido em três camadas radiais, cada uma com diferentes profundidades, otimizadas para registrar com eficiência as interações das partículas. A primeira camada apresenta segmentação muito fina e é utilizada principalmente para identificar decaimentos de partículas como o píon neutro. A segunda camada é responsável por registrar a maior parte da energia dos chuveiros eletromagnéticos gerados por essas partículas. Já a terceira camada tem uma segmentação mais ampla e é usada para estimar a energia que escapa do detector, ajudando a distinguir entre chuveiros eletromagnéticos e hadrônicos [7].

As placas de chumbo que funcionam como absorvedores mantêm constante a lacuna de LAr. Elas são reforçadas com tecido de fibra de vidro impregnado com resina para garantir resistência mecânica. A espessura dessas placas varia com $|\eta|$, visando otimizar a resolução de energia do calorímetro. Os eletrodos de leitura, posicionados entre os absorvedores, consistem em camadas condutoras de cobre segmentadas, o que proporciona resolução espacial tanto em η quanto em profundidade [7].

A geometria em acordeão garante cobertura contínua em ϕ sem fissuras, como ilustrado nas Figuras 8 e 9, permitindo a rápida extração dos sinais dos eletrodos, tanto pela parte frontal quanto pela traseira. No barril, as dobras do acordeão são axiais e percorrem o ângulo ϕ , com variação nos ângulos de dobra em função do raio, de modo a manter constante a largura da lacuna de LAr. Nas tampas, as dobras percorrem a direção axial, com variações de amplitude e ângulo conforme o raio, para compensar o aumento da lacuna líquida. Essa arquitetura resulta em excelente uniformidade de desempenho em termos de linearidade e resolução angular [9].

A Figura 8 mostra a *layout* da camada de sinal dos diferentes tipos de eletrodos antes da dobra. Na

Figura 9, observa-se, por exemplo, que na primeira camada do barril há oito tiras na frente de uma célula média, evidenciando sua alta granularidade em η . Entretanto, essa granularidade torna-se mais grosseira nas zonas de borda do barril e nas tampas. A segunda camada coleta a maior parte da energia do chuveiro eletromagnético, enquanto a terceira camada, mais superficial, mede apenas sua cauda, apresentando, por isso, menor segmentação [32].




Figura 8 – Layout da camada de sinal para os quatro tipos diferentes de eletrodos antes de dobrar. O dois eletrodos superiores são para o cilindro e os dois eletrodos inferiores são para a tampa interna (esquerda) e rodas externas (direita). As dimensões estão em milímetros. Os desenhos estão todos na mesma escala. [33]




Figura 9 – Esboço de um módulo de barril onde as diferentes camadas são claramente visíveis com o agrupamento de eletrodos em ϕ . A granularidade em η e ϕ das células de cada uma das três camadas e da torres de gatilho também são mostradas [33]

Os absorvedores são compostos por placas de chumbo às quais são coladas duas chapas de aço inoxidável de 0,2 mm de espessura usando tecido de fibra de vidro impregnado com resina para maior resistência mecânica. No barril, as placas de chumbo têm 1,53 mm de espessura para $|\eta| < 0,8$ e 1,13 mm para $|\eta| > 0,8$. Essa mudança na espessura do chumbo em $|\eta| = 0,8$ limita a redução da fração de amostragem à medida que $|\eta|$ aumenta. Nos calorímetros das tampas, as placas têm 1,7 mm de espessura para $|\eta| < 2,5$ e 2,2 mm para $|\eta| > 2,5$ [33].

Para assegurar medições precisas, especialmente em regiões com maior quantidade de material, o ECAL é segmentado longitudinal e transversalmente, com granularidades que variam conforme a pseudorapidez. Além disso, são utilizados pré-amostradores que corrigem as perdas de energia ocorridas antes da face frontal do calorímetro.

Os eletrodos de leitura estão localizados nos intervalos entre os absorvedores e consistem em três camadas condutoras de cobre separadas por folhas isolantes de poliimida. As duas camadas externas são mantidas em alta tensão, e a camada interna é usada para a leitura do sinal por meio de acoplamento capacitivo. A segmentação do calorímetro em η e profundidade é obtida por padrões gravados nas diferentes camadas, como mostrado na Figura 8. A segmentação em $|\phi|$ é obtida agrupando o número apropriado de eletrodos. Cada intervalo do barril entre dois absorvedores possui dois tipos de eletrodos: um para $|\eta| < 0,8$ e outro para $|\eta| > 0,8$. De forma semelhante, cada intervalo das tampas possui eletrodos específicos para $|\eta| < 2,5$ e outros para $|\eta| > 2,5$ [33].

Os sinais do ECAL são processados por pré-amplificadores e moldadores bipolares, com amostragem realizada a cada 25 ns. Os sinais extraídos das faces internas e externas do detector são enviados para pré-amplificadores localizados fora dos criostatos, próximos às passagens de alimentação. A leitura dos sinais ocorre de forma distinta para cada camada do calorímetro. A primeira camada é lida pela parte frontal, enquanto as segunda e terceira camadas são lidas pela parte traseira. A leitura é realizada por várias placas interconectadas, incluindo placas somadoras, que geram somas analógicas de lacunas adjacentes, e placas-mãe, responsáveis tanto pela leitura das somas analógicas quanto pela distribuição de pulsos de calibração [33].

Essa estrutura avançada permite ao ECAL não apenas detectar partículas, mas também diferenciá-las com alta precisão, sendo essencial para os experimentos de física de altas energias.

2.2.1.2 Calorímetro Hadrônico

Os calorímetros hadrônicos (HCAL) do ATLAS incluem o calorímetro de telhas, o calorímetro de argônio líquido na tampa final hadrônica e o calorímetro frontal de alta densidade. Esses sistemas, projetados para medir a energia de cascatas hadrônicas no LHC, estão localizados atrás do calorímetro eletromagnético e utilizam combinações específicas de materiais ativos e passivos para otimizar o desempenho e resistir à radiação [33].

O HCAL consiste em três calorímetros de amostragem distintos, cada um adaptado às diferentes demandas ao longo da vasta faixa de $|\eta| < 4,9$. Na região central ($|\eta| < 1,7$), o calorímetro de telhas cintilantes de ferro é utilizado nos barris principais e estendidos, com um calorímetro de telhas intermediário para preencher lacunas e fornecer espaço para cabos e serviços. Já na faixa de $1,5 < |\eta| < 4,9$, são empregados calorímetros de argônio líquido, como o calorímetro de tampa hadrônica até $|\eta| < 3,2$ e o calorímetro frontal de alta densidade até $|\eta| < 4,9$, compartilhando o criostato com os calorímetros

eletromagnéticos [33].

O agrupamento das fibras de leitura nos tubos fotomultiplicadores (PMTs) proporciona uma geometria aproximadamente projetiva em pseudorrapidez. A região de gap, localizada entre o barril principal e o barril estendido do calorímetro de telhas, corresponde a um espaço físico onde há descontinuidade na instrumentação padrão, necessário para a passagem de cabos e serviços do detector. Para evitar perdas de informação nessa faixa, essa região é equipada com módulos especiais compostos por sanduíches de aço-cintilador, mantendo a mesma fração de amostragem do restante do calorímetro. Além disso, detectores cintiladores mais finos são utilizados em setores com espaço ainda mais restrito dentro desses gaps, garantindo uma cobertura eficiente mesmo nas áreas de difícil acesso [33].

Um aspecto importante no projeto do HCal é sua espessura, projetada para conter eficazmente os chuveiros hadrônicos e minimizar a penetração nos sistemas de múons. O HCal demonstrou ser eficaz na redução da penetração de múons indesejados.

2.3 Algoritmo *NeuralRinger*

Os calorímetros e os detectores de rastreamento interno (*inner tracking detectors*) do ATLAS fornecem informações complementares para a identificação de elétrons. No entanto, o rastreamento demanda mais recursos computacionais, devido à sua estrutura de leitura significativamente mais densa e ao uso de algoritmos combinatórios. Para otimizar a utilização dos recursos do sistema, a discriminação precoce de elétrons avalia apenas as informações dos calorímetros, no primeiro nível de processamento (L1Calo). Os calorímetros eletromagnético e hadrônico do ATLAS possuem três camadas de amostragem cada, que, somadas à medição inicial do pré-amostrador, totalizam sete camadas de leitura [35].

Em seguida, o HLT emprega informações do calorímetro e, após uma pré-seleção, usa informações de rastreamento em duas etapas, uma computação rápida, seguida por uma etapa precisa, resultando em quatro etapas sequenciais indicadas na Figura 10 [35].

Nesse contexto, a seleção precisa de elétrons é usada para controlar a quantidade de eventos que o sistema permite passar para as etapas seguintes. Por outro lado, as etapas iniciais da seleção são especialmente importantes para lidar com as limitações impostas pelo volume de dados e pela capacidade de processamento. Assim, os algoritmos de *trigger* são projetados para respeitar essas restrições operacionais, mantendo o desempenho dentro dos limites aceitáveis [35].

Para garantir que os objetos de interesse — como os elétrons — sejam corretamente identificados durante a seleção em tempo real, os algoritmos de *trigger* são baseados nos mesmos princípios usados na reconstrução *offline*, que oferece uma descrição detalhada e precisa dos eventos. A reconstrução *offline* serve, portanto, como referência para o desenvolvimento do *trigger*. Dessa forma, busca-se que as decisões tomadas durante o processamento em tempo real sejam as mais próximas possíveis das obtidas com os algoritmos *offline*, assegurando alta eficiência na identificação dos sinais [35].

O algoritmo *NeuralRinger* tem sido usado desde 2017 na etapa *FastCalo* no experimento ATLAS. Esse algoritmo se baseia na característica de desenvolvimento lateral dos chuveiros de partículas, formando uma estrutura cônica ao redor da deposição inicial. Essa estrutura (Figura 11) permite que informações relevantes do chuveiro sejam codificadas em quantidades que descrevam a soma de energia de todas as células em anéis concêntricos gerados em cada camada do calorímetro [35].

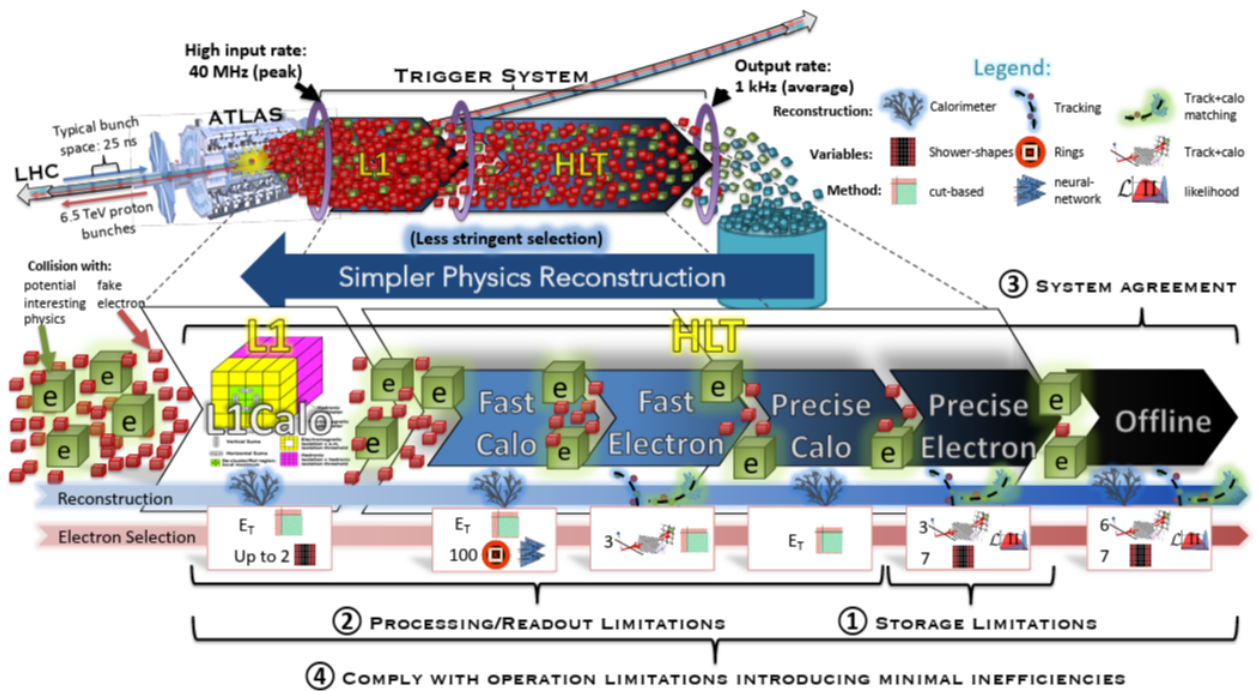


Figura 10 – Esboço do trabalho de processamento de dados eletrônicos realizado durante 2017 e 2018 - coleta de dados [35].

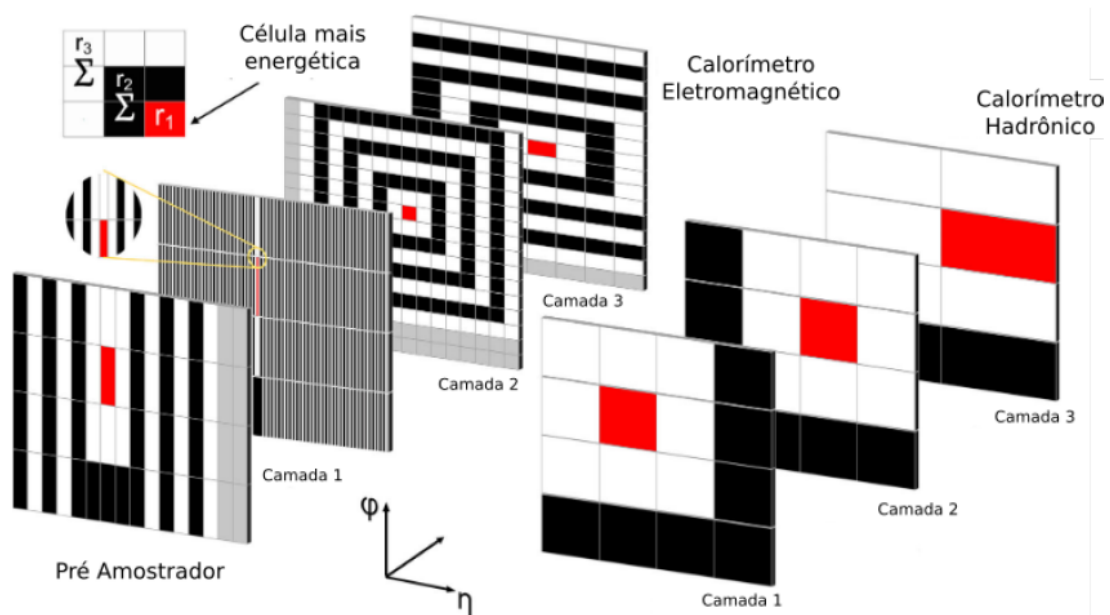


Figura 11 – Diagrama do processo de construção dos anéis. Devido à estrutura das células do calorímetro, esses anéis têm forma retangular. [36]

O processo de anelamento desempenha um papel essencial para o funcionamento do algoritmo *NeuralRinger*, sendo aplicado a todas as camadas do calorímetro. Esse processo tem início com a identificação da célula com a maior deposição de energia (*HotCell*), localizada dentro da Região de Interesse (RoI), que atua como o núcleo do primeiro anel. A partir dela, constroem-se anéis concêntricos sucessivos, somando-se a energia depositada em cada anel — como ilustrado na Figura 11 [37]. A quantidade de anéis gerados em cada camada do calorímetro depende do tamanho da RoI considerada. No

caso específico apresentado, adota-se uma RoI com dimensão $\Delta\eta \times \Delta\phi = 0,4 \times 0,4$, o que resulta nas quantidades de anéis listadas na Tabela 1.

Tabela 1 – Quantidade de anéis calculados para cada camada do calorímetro do ATLAS.

Camada	PS	EM1	EM2	EM3	H1	H2	H3
Anéis	8	64	8	8	4	4	4

A cada evento, a assinatura de deposição de energia fica registrada na estrutura composta por 100 somas em anéis, resultando em um fator de compactação de aproximadamente 10 vezes (considerando que a região de interesse tem aproximadamente 1000 sensores), simplificando a análise e interpretação dos dados. No entanto, os anéis por terem uma estrutura simétrica em relação à célula mais energética não conseguem capturar adequadamente possíveis assimetrias no perfil de deposição de energia nos calorímetros, que podem trazer informações relevantes adicionais para o processo de calibração [35].

2.4 Quarter Rings

A estrutura assimétrica denominada *Quarter Rings* (QR), Figura 12, é obtida a partir da divisão de cada *Standard Rings* em quatro partes, com exceção do primeiro anel (*Hotcell*). Desta forma, considerando todas as camadas do sistema de calorimetria, existem 379 *Quarter Rings*, correspondentes aos 100 *Standard Rings* originais. Na representação esquemática da Figura 12 pode-se observar a equivalência entre *Quarter Rings* e *Standard Rings* - os anéis QR1, QR2, QR3 e QR4 combinados formam um *Standard Ring* [11].

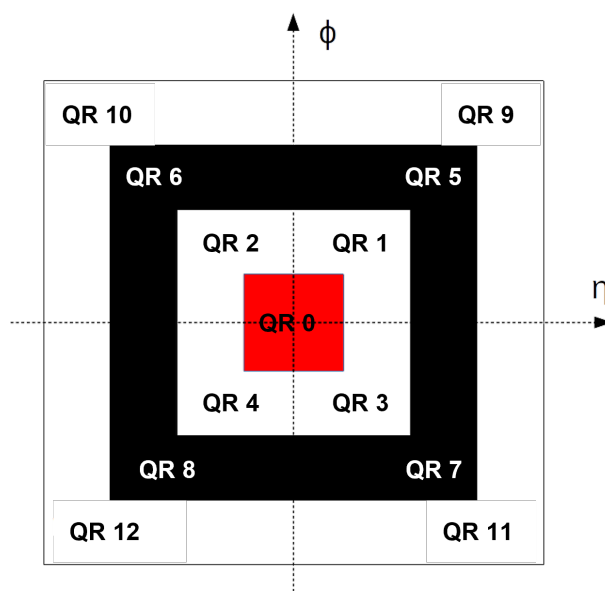


Figura 12 – Diagrama simplificado do processo de construção dos anéis. Devido à estrutura das células do calorímetro, esses anéis têm forma retangular. [11]

Devido à segmentação em quadrantes dos *Quarter Rings*, é possível capturar assimetrias no perfil de deposição de energia do chuveiro de partículas, oferecendo uma granularidade mais fina em comparação aos *Standard Rings*. Essa granularidade mais refinada proporciona uma leitura mais detalhada das regiões do calorímetro, favorecendo uma caracterização mais precisa dos perfis lateral e longitudinal

do chuveiro eletromagnético. Com isso, torna-se possível identificar variações locais sutis na distribuição de energia, que poderiam ser mascaradas em uma estrutura com granularidade mais grosseira.

A capacidade dos *Quarter Rings* de capturar detalhes mais refinados na distribuição de energia é explorada neste trabalho com o objetivo de aprimorar os métodos de calibração do sistema de calorimetria. A Tabela 2 apresenta a disposição dos *Quarter Rings* em cada camada, evidenciando a granularidade mais fina em comparação aos *Standard Rings*, Tabela 1. O estudo concentra-se na investigação dos efeitos do uso dessa estrutura assimétrica na calibração, avaliando os ganhos potenciais na estimação do fator de correção e, conseqüentemente, na melhoria da precisão das medidas finais.

Tabela 2 – *Quarter Rings* dispostos por camada no sistema de calorimetria do experimento ATLAS.

Camada	PS	EM1	EM2	EM3	H1	H2	H3
Anéis	29	253	29	29	13	13	13

2.5 Seleção online (*trigger*) de elétrons no experimento ATLAS

No experimento ATLAS do LHC, o sistema de *trigger* seleciona em tempo real quais colisões de partículas devem ser registradas para análises posteriores. Como o ATLAS monitora colisões próton-próton a cada 25 ns, é gerada uma taxa de dados de até 70 TB por segundo, tornando inviável armazenar integralmente todas as informações.

Para superar esse desafio, o *trigger* atua de forma *online*, filtrando eventos e selecionando aqueles com características físicas relevantes — como léptons de alta energia, fótons, jatos ou energia transversa ausente — enquanto descarta com eficiência colisões sem relevância [38], [39], [40]. Esse processo é essencial para garantir que apenas os dados mais promissores sejam preservados, otimizando os recursos computacionais e de armazenamento do experimento (Figura ??).

O sistema de *trigger* do ATLAS foi eficaz durante os períodos *Run 1* (2009–2013) e *Run 2* (2015–2018) do LHC. Atualmente, está sendo atualizado para o *Run 3* (2022–2025), que trará um aumento moderado na energia e na intensidade das colisões [40].

Os termos *Run 1*, *Run 2* e *Run 3* se referem a diferentes períodos oficiais de operação do LHC e dos seus experimentos, como o ATLAS. Cada “*Run*” é uma fase de coleta de dados que ocorre entre paradas programadas para manutenção, atualizações e melhorias no acelerador e nos detectores.

O *Run 3* (2022–2025) do LHC trouxe um aumento na energia no centro de massa das colisões (de 13 para 13,6 TeV) e na luminosidade instantânea de pico (até $2.1 \times 10^{34} \text{ cm}^{-2} \cdot \text{s}^{-1}$). Este último resultará em um aumento no número médio de colisões simultâneas (*pile-up*), passando de 40 para 65, o que aumentará a demanda sobre os sistemas de *trigger* dos experimentos [38].

O L1 seleciona eventos a partir de informações simplificadas do detector, identificando regiões de interesse (RoI) com alta energia. Ele é formado pelo *trigger* do calorímetro (L1Calo) e pelo *trigger* de múons (L1Muon). As informações destes são combinadas no processador topológico (L1Topo), que calcula grandezas como a separação angular entre objetos físicos. Esses dados são integrados no Processador Central de *Trigger* (CTP), que decide a seleção final do evento segundo um conjunto predefinido de critérios. A taxa máxima de eventos selecionados pelo L1 é limitada a 100 kHz, devido às restrições do sistema de leitura do detector [39].

Implementado em hardware especializado localizado próximo ao detector, o L1 processa sinais do calorímetro de Argônio Líquido, do calorímetro *Tile* e do Espectrômetro de Múons para tomar decisões em apenas 2,5 microssegundos. Assim, ele reduz os 40 milhões de eventos por segundo gerados pelo LHC para cerca de 100 mil, que seguem para análise detalhada [40].

Se um evento é selecionado nesta primeira etapa, ele avança para o segundo nível do sistema de *trigger*, conhecido como *High Level Trigger* (HLT), para ser analisado em mais detalhes. O HLT opera a partir de um amplo parque computacional com cerca de 50.000 aplicações de processamento. Em apenas 200 a 400 ms, os algoritmos sofisticados do HLT executam uma análise detalhada de regiões específicas do detector, selecionando cerca de 3.000 eventos por segundo e enviando-os para armazenamento permanente para análise posterior pelos diversos grupos de física [40]. A etapa *Fast Calorimeter Reconstruction* (FastCalo) é de especial importância para este trabalho pois é ali que ocorre a seleção de eventos baseada no algoritmo *NeuralRinger*.

O sistema de *trigger* de alto nível depende de informações de calorímetros e, portanto, é suscetível a erros de medição de energia. Por esse motivo, a calibração é proposta na etapa rápida do HLT como pode ser observado na Figura 13.

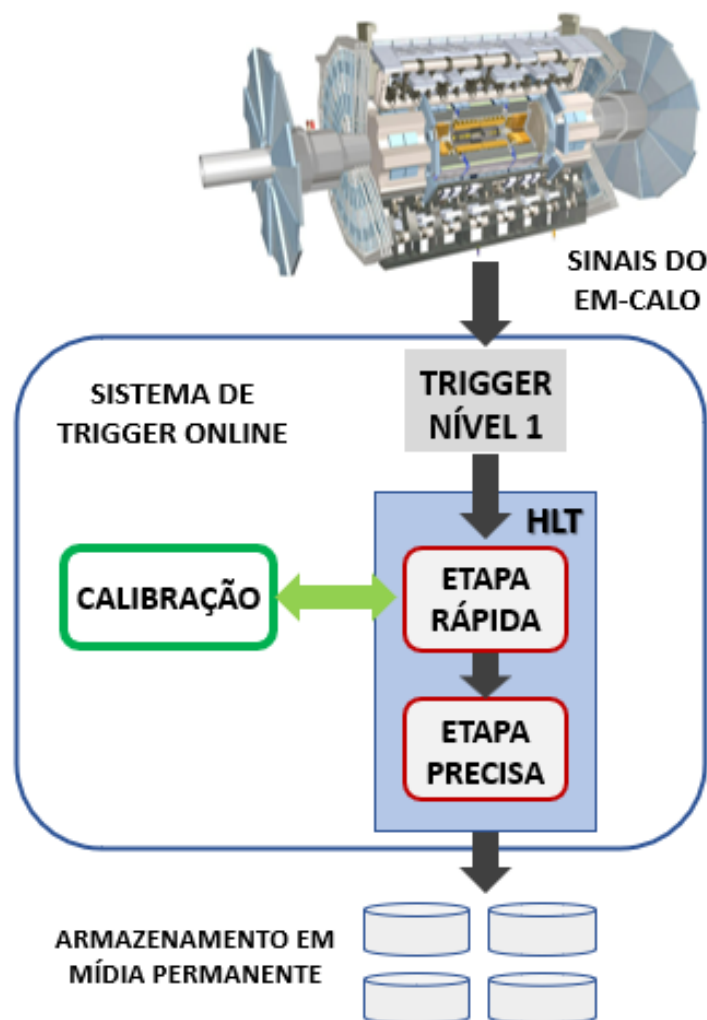


Figura 13 – Diagrama do sistema de seleção *online* (*trigger*) de elétrons do detector ATLAS [11].

Esse rigoroso processo de seleção de eventos permite que o ATLAS otimize a utilização dos dados coletados, maximizando assim a busca por mais novas descobertas e avanços significativos.

3 Calibração de Energia Usando Aprendizado de Máquina

A calibração desempenha um papel crucial na melhoria da qualidade dos resultados obtidos em experimentos científicos. No que se refere a este trabalho, ao ajustar os dados brutos coletados pelo calorímetro, a calibração garante que as estimativas de energia das partículas detectadas sejam mais precisas e confiáveis. Esse refinamento na estimação de energia não só aumenta a qualidade das medições, mas também contribui, potencialmente, para uma melhor discriminação entre os sinais de interesse e o ruído de fundo, facilitando a identificação e seleção dos eventos relevantes para análise do processo físico de interesse.

Quando uma partícula interage com o calorímetro, ela gera um chuveiro de partículas secundárias, cuja energia é gradualmente dissipada. A energia depositada pelas partículas carregadas nesse chuveiro é detectada na forma de carga elétrica ou luz, fornecendo uma medida da energia da partícula incidente [35]. É importante notar que o processo de detecção é destrutivo, impedindo a recuperação da partícula absorvida pelo calorímetro.

A energia das partículas eletromagnéticas, Figura 14, é calculada somando as contribuições das células das camadas E1, E2 e E3 dentro de uma região de interesse *Region of Interest* (RoI) em torno da célula com maior energia. Isso pode ocasionar perda de informação de três formas principais: lateral, quando a energia se espalha além da RoI; longitudinal, ao atravessar para as camadas hadrônicas; ou pela interação da partícula com o material do detector [11], [14].




Figura 14 – Ilustração das principais causas dos erros na estimação da energia total da partícula ao interagir com o calorímetro do ATLAS [11].

Mediante isso, o procedimento de calibração tenta corrigir os fatores de erro de medição. A abordagem adotada neste trabalho consiste em treinar um regressor baseado tanto em GBDT quanto em Rede Neural com dados simulados. O fator de calibração α é definido por:

$$\alpha = \frac{E_{Truth}}{E_{Fast}}, \quad (3.1)$$

onde E_{Truth} é a energia simulada por Monte Carlo e E_{Fast} é a energia estimada na etapa rápida do HLT [12]. O fator de correção α é aplicado à energia bruta estimada no *FastCalo* usando as camadas eletromagnéticas, de tal forma que o valor se aproxime do valor de referência (E_{Truth}).

A regressão é uma tarefa de aprendizado supervisionado usada para modelar a relação entre uma ou mais variáveis de entrada e uma variável de saída. O objetivo de um modelo de regressão é prever um valor numérico com base nas informações fornecidas pelas variáveis de entrada. Técnicas como GBDT e redes neurais são amplamente utilizadas para resolver problemas de regressão, especialmente quando há relações não lineares e interações complexas entre as variáveis envolvidas [41].

Neste contexto, a calibração das medições de energia do calorímetro do experimento ATLAS foi realizada com o uso de técnicas de *Gradient Boosted Decision Trees* (GBDT) e Redes Neurais, escolhidas por sua capacidade de lidar com a complexidade dos dados experimentais, bem como por sua robustez frente a ruídos e valores discrepantes, além do baixo tempo de inferência, uma característica fundamental para sua aplicação no sistema de *trigger* [42], [41].

O *Gradient Boosted Decision Trees* (GBDT) adota uma abordagem sequencial e iterativa baseada em gradientes, na qual cada nova árvore é treinada para minimizar uma função de perda ajustando-se aos resíduos do modelo anterior [43]. Em vez de modificar diretamente os pesos das amostras, como fazem alguns algoritmos de *boosting*, o GBDT busca prever as falhas residuais das iterações anteriores. Ou seja, cada etapa foca em aprender o que ainda não foi capturado corretamente, refinando progressivamente as previsões [44]. Essa estratégia permite capturar relações não lineares complexas entre as variáveis de entrada e o fator de calibração, o que é especialmente relevante no contexto do calorímetro, cuja resposta depende de diversos fatores físicos e geométricos [42, 44].

Neste trabalho, o GBDT é treinado utilizando atributos extraídos de cada evento, como a energia depositada nas diferentes camadas do calorímetro e a pseudorapidez da partícula. A aplicação desse modelo possibilita uma calibração mais precisa da energia medida, compensando variações locais na resposta do detector e aprimorando a acurácia das estimativas energéticas.

A rede neural é um modelo computacional inspirado no funcionamento do cérebro humano, amplamente utilizado para resolver problemas complexos de aprendizado de máquina. Ela é composta por camadas de unidades interconectadas que processam e transmitem informações de forma hierárquica.

A rede neural utilizada neste trabalho é do tipo *Feedforward Multilayer Perceptron* (MLP), composta por múltiplas camadas densamente conectadas. Cada neurônio realiza uma combinação linear das entradas seguida por uma função de ativação não linear, permitindo ao modelo aprender padrões complexos e relações sutis presentes nos dados [43]. Essa flexibilidade e a capacidade de generalização das redes neurais tornam a MLP uma boa opção para calibração, especialmente em regiões onde a resposta do calorímetro apresenta maior variabilidade.

As redes neurais *Feedforward* recebem esse nome porque a informação flui em uma única direção: das entradas, passando pelas camadas ocultas, até as saídas. Não existem conexões de retorno; ou seja, as saídas geradas não são realimentadas às camadas anteriores, garantindo um fluxo de dados estritamente unidirecional [42].

Cada camada oculta pode ser representada por um vetor, cuja dimensão é definido pelo número de neurônios. Cada elemento desse vetor corresponde a uma unidade, que recebe múltiplas entradas de outras unidades e calcula um valor de ativação. Assim, uma camada pode ser vista tanto como uma função que mapeia vetores em vetores, quanto como um conjunto paralelo de funções que mapeiam vetores em escalares, onde cada função representa a ativação de uma unidade [42].

Essas redes também são caracterizadas pela composição de várias funções, organizadas em camadas sucessivas. Por exemplo, três funções $f^{(1)}$, $f^{(2)}$ e $f^{(n)}$ conectadas em sequência, formando:

$$f(x) = f^{(n)}(f^{(2)}(f^{(1)}(x))), \quad (3.2)$$

Nesse caso, $f^{(1)}$ é chamada de primeira camada da rede, $f^{(2)}$ é chamada de segunda camada e assim por diante. A última camada é conhecida como camada de saída. Durante o treinamento da rede neural, o objetivo é ajustar a função $f(x)$ para aproximar da melhor forma possível com a função $f^*(x)$. Essa função $f^*(x)$ representa a verdadeira relação entre a entrada e a saída nos dados — ou seja, a função que se desejaria modelar se todos os dados fossem perfeitos e livres de ruído. Os dados de treinamento nos fornecem apenas exemplos aproximados e ruidosos de $f^*(x)$, avaliados em diferentes pontos de treinamento. O algoritmo de aprendizado deve decidir como utilizar essas amostras para alcançar a saída desejada, implementando uma aproximação eficiente de f^* [42].

Entretanto, um dos principais desafios dessa abordagem é o risco de *overfitting*, ou sobreajuste, que ocorre quando o modelo se ajusta excessivamente aos dados de treinamento, o que compromete sua capacidade de generalizar e produzir boas previsões para novos conjuntos de dados. Esse risco é especialmente relevante quando o número de iterações é elevado. Nessa condição, o modelo pode memorizar os exemplos específicos de treinamento em vez de aprender padrões gerais, prejudicando o desempenho do treinamento tanto da GBDT quanto da rede neural [43].

Para mitigar esse problema, uma estratégia eficaz é a aplicação da técnica de parada antecipada (*Early Stopping*), que consiste em monitorar continuamente o desempenho do modelo em um conjunto de validação separado ao longo do treinamento. Como esse conjunto não participa diretamente do ajuste do modelo, ele fornece uma estimativa mais realista da capacidade de generalização do modelo. O treinamento é interrompido assim que o desempenho no conjunto de validação deixa de melhorar, evitando o ajuste excessivo aos dados de treinamento [43].

A validação cruzada é uma técnica estatística amplamente utilizada para avaliar o desempenho de modelos de aprendizado de máquina e estimar o erro de generalização de um modelo treinado. Seu objetivo principal é medir como o modelo se comporta ao fazer previsões em dados não vistos, simulando cenários do mundo real, nos quais o modelo é aplicado a novos conjuntos de dados.

Na validação cruzada *k-fold*, o parâmetro k corresponde a um número inteiro que define em quantas partes, de tamanhos aproximadamente iguais, o conjunto de dados será particionado. Em cada iteração, uma partição é utilizada como conjunto de validação, enquanto as outras $k - 1$ partições são

usadas para treinar o modelo [41].

A escolha do valor de k é crucial na validação cruzada. Quando $k = N$ (sendo N o número total de objeto), obtém-se uma estimativa praticamente não enviesada do erro de previsão. No entanto, isso pode levar a uma alta variabilidade, uma vez que os conjuntos de treinamento se tornam muito semelhantes entre si, além de aumentar significativamente o custo computacional. Por esse motivo, valores como $k = 5$ ou $k = 10$ são amplamente utilizados, pois oferecem um bom equilíbrio entre viés e variância, embora possam introduzir algum viés dependendo da sensibilidade do modelo ao tamanho do conjunto de treinamento [45].

Os modelos desenvolvidos foram aplicados a um conjunto de dados simulados do experimento ATLAS, que pode ser acessado em <https://bigpanda.cern.ch/task/28584754/>, que contém informações essenciais como energia, posição e características das partículas detectadas pelo calorímetro. O principal objetivo é calibrar esses dados para melhorar a precisão das medições realizadas pelo detector. Este aspecto é particularmente crítico em níveis de energia mais baixos, onde a identificação de elétrons pode se tornar mais desafiadora devido às características específicas do perfil de deposição de energia.

Na Figura 15 apresenta um histograma que representa a energia transversa simulada dos eventos. O código responsável pela geração do gráfico foi implementado utilizando a biblioteca *ROOT*, por meio da interface *PyROOT* em *Python*. Essa ferramenta é amplamente utilizada em física de altas energias. No histograma, os limites horizontal e vertical da energia transversa são obtidos diretamente dos dados.

O gráfico revela uma concentração significativa de eventos nas baixas energias transversas, com um pico acentuado nas primeiras faixas. A distribuição apresenta uma cauda longa, estendendo-se até energias da ordem de 3 TeV, com um número reduzido de eventos em regiões de alta energia. Além disso, o gráfico incorpora uma janela de *zoom* sobreposta, ampliando a região entre 0 e 500.000 MeV. Essa visualização auxiliar destaca com mais detalhes a estrutura da distribuição nas regiões de maior deposição de energia.

A Figura 16 apresenta um histograma da distribuição de energia correspondente à pseudorapidez (η). A pseudorapidez é uma variável angular fundamental em Física de Altas Energias, pois permite descrever a posição de partículas em relação ao eixo do feixe. Por isso, é amplamente utilizada para caracterizar a cobertura e a geometria dos detectores em experimentos como os do LHC. O gráfico também foi produzido pela biblioteca *ROOT*, acessada via *PyROOT* em *Python*. Definindo-se um histograma no intervalo de η entre -3 e +3. A análise visual do histograma revela que a distribuição de eventos é aproximadamente uniforme na região próxima a -2,5 a 2,5, porém a contagem se mantém na faixa de 14.000 eventos. Este histograma da pseudorapidez oferece uma visão clara da distribuição espacial dos eventos no detector, sendo uma ferramenta fundamental para a validação da geometria do sistema de detecção e da qualidade da reconstrução dos dados simulados.

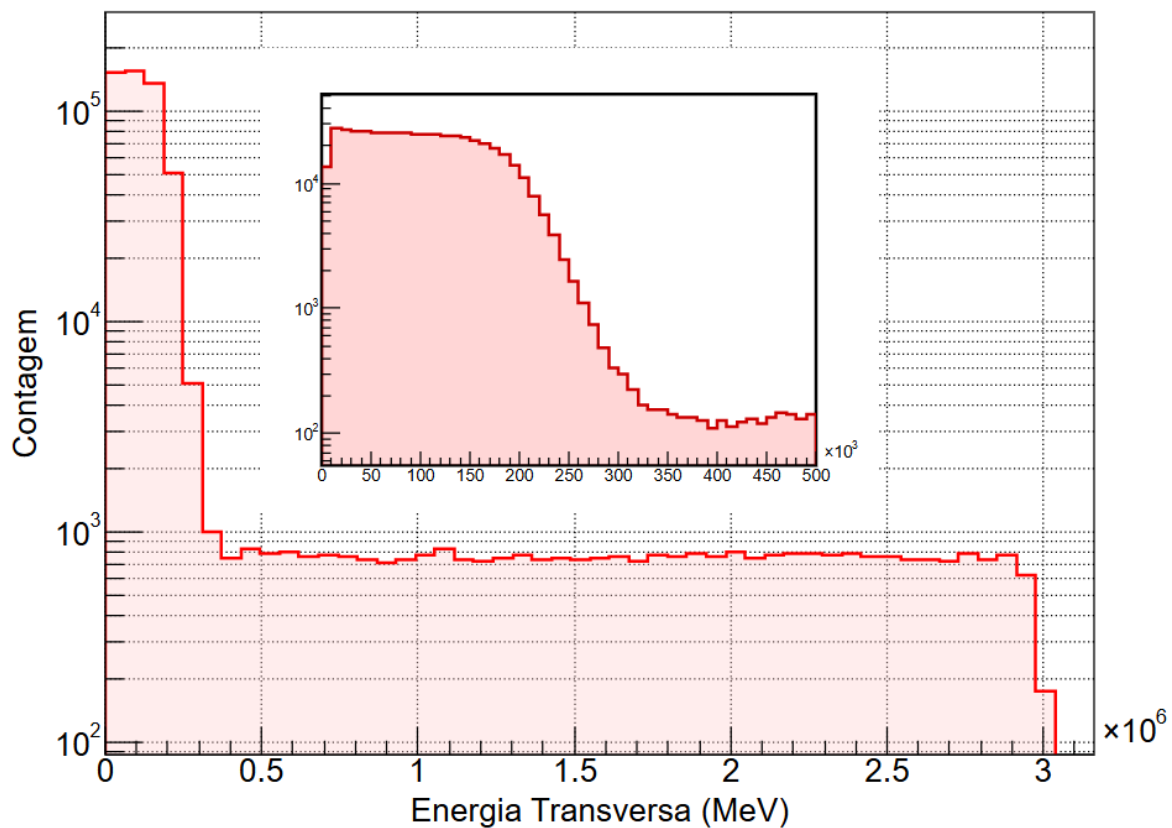


Figura 15 – Perfil de distribuição em E_t .

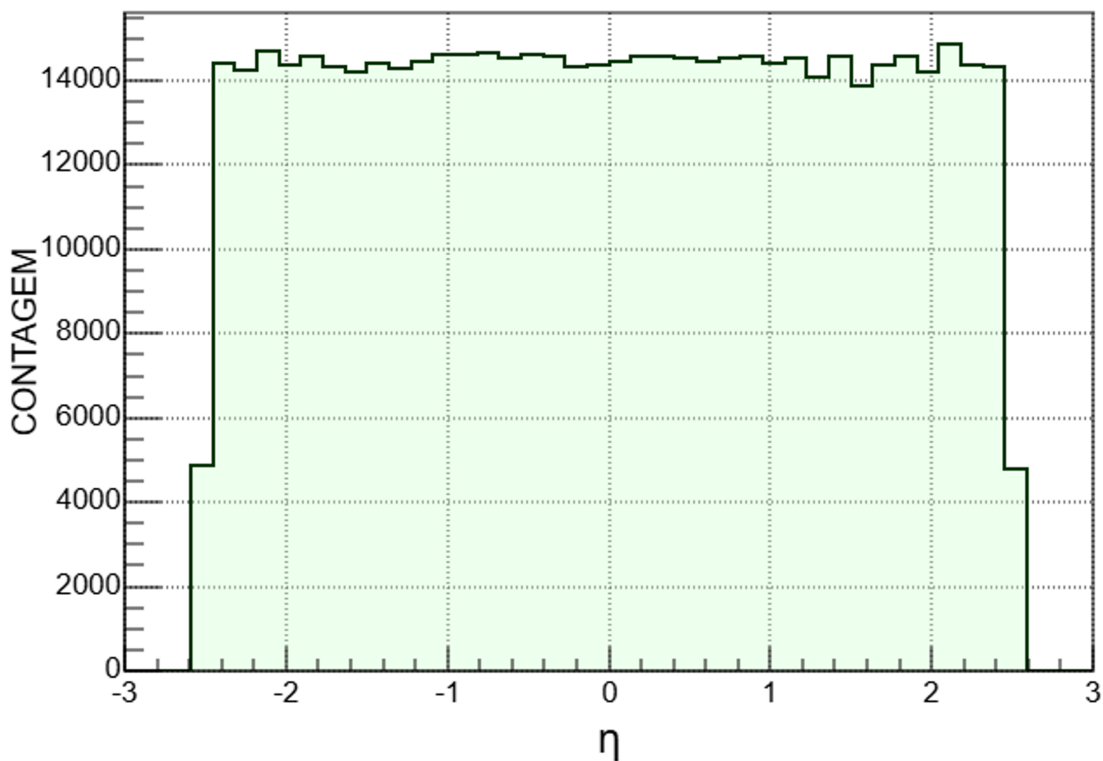


Figura 16 – Perfil de distribuição em η .

A segmentação do calorímetro é motivada pelo fato da resposta do calorímetro não ser uniforme ao longo de toda a faixa de energia transversa (E) e pseudorapidez (η). O desempenho do calorímetro tende a ser melhor em altas energias, enquanto nas faixas de baixa energia a identificação de partículas torna-se mais desafiadora.

Além disso, a pseudorapidez está diretamente relacionada à região do detector onde o chuveiro eletromagnético se desenvolve. Regiões como o barril central apresentam resposta mais estável e precisa, ao passo que áreas de transição, como o *crack* entre o barril e os *endcaps*, apresentam maior complexidade e pior desempenho devido à geometria e à heterogeneidade dos materiais. Portanto, tratar o detector como homogêneo nessas variáveis comprometeria a eficácia da calibração [32].

O detector responde de forma diferentes em relação a posição geométrica da pseudorapidez e da energia. Por isso, este trabalho adotou uma abordagem segmentada para calibrar o calorímetro, realizando o processo separadamente em intervalos específicos de $|\eta|$ e energia. Os intervalos foram definidos heurísticamente para garantir uma cobertura adequada tanto em altas quanto baixas energias. A estratégia buscou equilibrar a quantidade de faixas em diferentes níveis de energia, mantendo a consistência nos resultados. Essa abordagem permite uma calibração mais precisa, adaptada às características individuais de cada região do detector e faixa de energia, garantindo uma resposta confiável no processo de calibração. Os limites dos intervalos de $|\eta|$ e de energia empregados foram:

- $|\eta|$: [0; 0,6; 0,8; 1,2; 1,37; 1,52; 1,8; 2,0; 2,2; 2,5]
- E_t (GeV): [0; 5; 10; 20; 30; 40; 50; 70; 100; 150; 200; 250; 900; 3000]

4 Metodologia

Neste capítulo, são discutidos os métodos utilizados para a calibração do calorímetro do ATLAS, Figura 17, analisando como diferentes configurações de entrada influenciam o desempenho e a capacidade de generalização de dois modelos de regressão: o *Gradient Boosted Decision Trees* (GBDT) e uma Rede Neural do tipo *Feedforward Multilayer Perceptron* (MLP). O desempenho de ambos modelos é avaliado com a aplicação da validação cruzada, destacando os impactos dessa técnica na robustez das previsões.

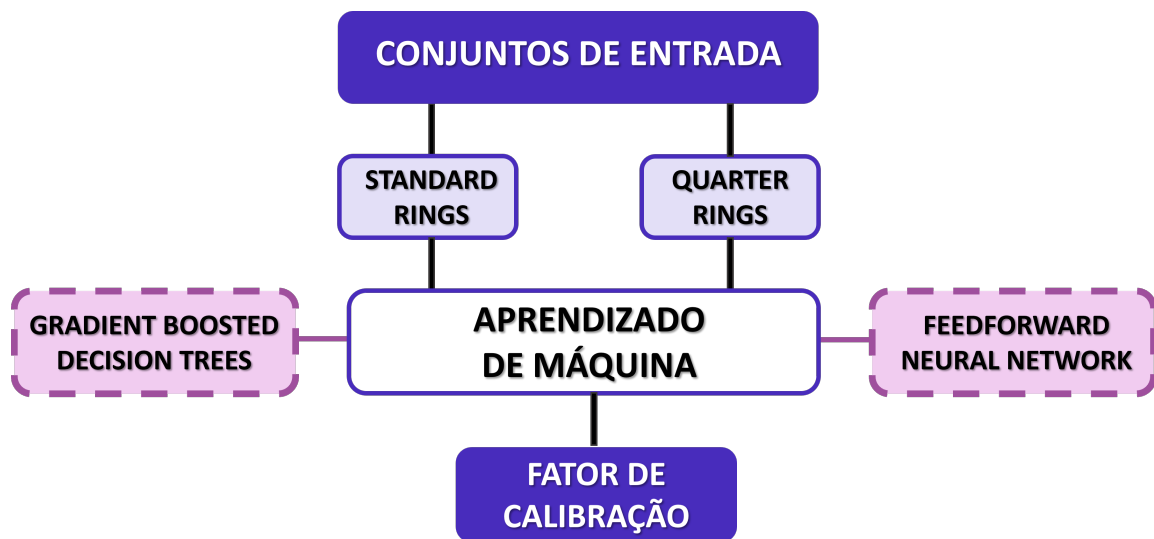


Figura 17 – Métodos utilizados para a calibração do calorímetro.

Para a análise, foram considerados dois conjuntos de entrada distintos: *Standard Rings* e *Quarter Rings*. Além disso, os resultados obtidos com os modelos calibrados foram comparados às estimativas fornecidas pelo *FastCalo*, que não incorpora calibração, servindo como referência de desempenho.

A investigação incluiu a avaliação do impacto do efeito de *pile-up* no processo de calibração. O *pile-up* refere-se à ocorrência de múltiplas colisões de prótons simultâneas em um único cruzamento de feixes no LHC. Essas colisões adicionais, além da colisão principal de interesse, geram sinais no detector que podem ser erroneamente atribuídos à colisão primária[46].

Como resultado, o *pile-up* representa um conjunto de colisões secundárias que complicam a identificação e a análise precisa dos eventos físicos principais. Esse fenômeno interfere na identificação e medição precisas das partículas produzidas, adicionando complexidade à análise experimental [47]. Os dados simulados utilizados neste estudo apresentam valores de *pile-up* caracterizados pelo número médio de interações próton-próton por evento ($\langle \mu \rangle$), variando na faixa de 25 a 52.

Para otimizar os hiperparâmetros da GBDT e da Rede Neural, foi empregada a técnica de otimização bayesiana, que modela a função de perda como probabilística. Ao contrário de abordagens como busca em grade ou busca aleatória, que podem ser exaustivas ou ineficientes, a otimização bayesiana reduz o custo computacional ao construir um modelo substituto, frequentemente baseado em Processos Gaussianos, para estimar a função de perda [48].

Essa abordagem equilibra eficientemente a exploração de novas regiões do espaço de hiperparâmetros com o refinamento de áreas promissoras. Guiada por uma função de aquisição que leva em conta tanto o valor esperado quanto a incerteza associada, a otimização foca nos ajustes mais promissores, otimizando a busca de maneira iterativa e inteligente [49].

Utilizou-se a biblioteca Keras para otimizar todos os parâmetros da rede neural e para a otimizar os parâmetros da GBDT foi utilizada a biblioteca *Scikit-optimize*. Em ambas as situações, cada configuração proposta de hiperparâmetros foi avaliada pelo desempenho resultante do modelo, retroalimentando o modelo probabilístico e refinando as escolhas subsequentes. Essa abordagem permitiu um ajuste fino e eficiente, maximizando o desempenho dos modelos sem a necessidade de buscas exaustivas.

Neste trabalho, os modelos de aprendizado de máquina foram treinados utilizando duas abordagens distintas. No primeiro, denominado método dos dados brutos, os valores de energia registrados diretamente nos anéis — tanto nos *Standard Rings* quanto nos *Quarter Rings* — foram utilizados como entradas para os modelos. Nessa abordagem, os próprios valores energéticos brutos, medidos em cada anel do calorímetro, são fornecidos diretamente como atributos ao algoritmo de treinamento.

No segundo método, denominado método extração de atributos das variáveis energéticas e assimétricas, desempenha um papel fundamental na eficácia dos modelos de aprendizado de máquina, especialmente na calibração de energia em calorímetros de experimentos de altas energias, onde os dados apresentam alta dimensionalidade e complexidade física. O objetivo dessa etapa é melhorar o desempenho dos modelos, a capacidade de generalização e reduzir a dimensionalidade dos dados de entrada. Nesta etapa, também será realizada uma análise com base na extração de atributos utilizando o logaritmo da soma das energias depositadas no calorímetro, pois o perfil do detector de deposição da energia apresenta um comportamento logarítmico [50].

A extração de atributos foi baseada tanto em princípios físicos do funcionamento do calorímetro quanto em boas práticas de modelagem estatística. A seleção de atributos visou capturar as características mais relevantes da distribuição de energia no detector, reduzindo redundâncias, minimizando o impacto de ruído e facilitando a generalização dos modelos. A Tabela 3 apresenta um resumo das estratégias consideradas para a construção das entradas dos modelos.

Tabela 3 – Métodos utilizados para a calibração do calorímetro.

Método	Descrição	Tipo de Atributo	Número de Atributos
Método 1	Utiliza diretamente dos <i>Standard Rings</i> e <i>Quarter Rings</i> .	Bruto	<i>Standard Rings</i> : 100 <i>Quarter Rings</i> : 379
Método 2	Aplica extração de atributos sobre os dados. Incorpora conhecimento especializado da física do experimento.	Extração de Atributos das Variáveis Energéticas e Assimétricas	<i>Standard Rings</i> : 28 <i>Quarter Rings</i> : 152

A seleção dos atributos têm como base a distribuição de energia e a interação das partículas nas diferentes camadas do calorímetro. Os atributos extraídos foram:

- Energia Total nos Anéis: Refere-se à soma da energia depositada em anéis concêntricos ao redor do ponto de impacto da partícula.
- Energia na Região Hadrônica: Indica a quantidade de energia depositada nas camadas mais profundas do calorímetro, que são responsáveis por absorver partículas hadrônicas.
- Energia Total nas Camadas Eletromagnéticas : Soma da energia depositada nas camadas do calorímetro eletromagnético. Esse atributo é importante para identificar partículas como elétrons e fótons, que interagem principalmente com essas camadas.
- Energia de Monte Carlo: Representa a energia simulada de uma partícula gerada via método Monte Carlo. É usado para comparação com os dados medidos, auxiliando na verificação e na validação dos resultados experimentais.
- Posição da Célula Mais Energética: Localização da célula do calorímetro que registrou a maior energia.
- Distancia do Baricentro ($\Delta\eta$ e ΔE): Esses dois atributos medem o deslocamento entre a posição da célula mais energética e o baricentro (ou centro de massa energética). Eles indicam o quanto a energia está centrada em torno da célula mais energética ou o quanto está espalhada.
- Diferença de Energia entre Anéis Vizinhos (η e Φ): Refere-se à diferença de energia entre anéis vizinhos no calorímetro, levando em conta a pseudorapidez (η) e o ângulo azimutal (Φ).

A assimetria do fluxo de energia na direção η pode ser observada a partir da diferença de energia entre anéis vizinhos, conforme ilustrado na Figura 12. A direção η denota a pseudorapidez e o Φ representa o ângulo azimutal. Para calcular essas assimetrias, usou-se as diferenças de energia entre dois pares dos *Quarter Rings*, conforme as seguintes equações:

1 . A diferença de energia na direção positiva de η e Φ é dada por:

Para η quando $\Phi = \Phi^+$:

$$\Delta E(\eta|\Phi = \Phi^+) = E(QR1) - E(QR2), \quad (4.1)$$

Para Φ quando $\eta = \eta^+$:

$$\Delta E(\Phi|\eta = \eta^+) = E(QR1) - E(QR3), \quad (4.2)$$

2 . A diferença de energia na direção negativa de η e Φ é dada por:

Para η quando $\Phi = \Phi^-$:

$$\Delta E(\eta|\Phi = \Phi^-) = E(QR3) - E(QR4), \quad (4.3)$$

Para Φ quando $\eta = \eta^-$:

$$\Delta E(\Phi|\eta = \eta^-) = E(QR2) - E(QR4). \quad (4.4)$$

Os índices $+$ e $-$ em η e Φ indicam, respectivamente, as direções positiva e negativa dos eixos correspondentes, que no contexto do detector ATLAS representam os lados direito e esquerdo do calorímetro. Ou seja, η^+ e Φ^+ correspondem à região do detector situada no lado direito, enquanto η^- e Φ^- indicam o lado esquerdo.

A extração de atributos trouxe benefícios significativos ao processo de calibração, que consiste em uma sequência estruturada de etapas — como pré-processamento, seleção de variáveis, treinamento e avaliação de modelos — organizadas de forma encadeada para tornar o fluxo de trabalho mais eficiente. Essa organização, comumente chamada de *pipeline*, permitiu reduzir a dimensionalidade do conjunto de dados, tornando os modelos mais eficientes em termos computacionais e menos propensos ao *overfitting*. Além disso, ao concentrar a representação em variáveis fisicamente relevantes, aumentou-se a interpretabilidade dos modelos e sua capacidade de generalização.

A presença de *outliers* pode comprometer a eficácia dos gráficos de controle. Um *outlier* é qualquer valor que se afaste significativamente dos demais em um conjunto de dados. Quando os dados contêm valores discrepantes, os limites de controle podem ser deslocados, dificultando a detecção de variações significativas que realmente indicam problemas no processo [51].

Como principal índice de desempenho na comparação das abordagens, foi utilizada a distância interquartílica (IQR) para medir a dispersão na estimativa do fator α . O IQR quantifica a amplitude entre o primeiro quartil (Q_1) e o terceiro quartil (Q_3) de um conjunto de dados. Ele reflete a variabilidade dos 50% dos dados centrais, ou seja, a diferença entre o valor que separa os 25% menores valores (Q_1) e os 25% maiores (Q_3). Sendo assim, o IQR é dado por:

$$IQR = Q_3 - Q_1. \quad (4.5)$$

Uma das vantagens do IQR é que ele não é afetado por valores extremos, o que o torna uma medida mais robusta de dispersão, mesmo em conjuntos de dados que contêm *outliers* [52]. Para evitar a sensibilidade aos *outliers*, podemos observar a amplitude dos dados depois da exclusão dos valores de cada ponta. Formalmente, esses tipos de estimativas são baseados em diferenças entre percentis [52]. Isso o torna ideal para conjuntos de dados não gaussianos ou assimétricos.

Se a calibração de fato melhorar a estimação da energia no *FastCalo*, espera-se que a distribuição dos valores calibrados de α apresente menor espalhamento. Além disso, o IQR é útil para avaliar a diferença entre o uso dos *Standard Rings* e *Quarter Rings* como entradas para o regressor.

Para a avaliação do desempenho dos modelos, tanto o GBDT quanto a Rede Neural foram submetidos ao método de validação cruzada *k-fold* [45]. Neste estudo, adotou-se $k = 5$. Em cada iteração, quatro partições foram utilizadas para o treinamento, enquanto a restante foi reservada para validação. Ambos os modelos foram avaliados em dois conjuntos distintos de dados: um contendo 530.010 assinaturas, correspondente ao cenário sem *pile-up*, e outro com 241.929 assinaturas, referente aos dados com *pile-up*. Esses dados foram obtidos a partir dos dados simulados, que consiste em eventos de elétrons individuais gerados no contexto da campanha MC21, considerando condições com e sem *pile-up* (com $\langle \mu \rangle$ variando de 25 a 55). Cada conjunto foi dividido em 70% para treinamento e 30% para teste, assegurando uma avaliação abrangente em diferentes condições experimentais.

Após o treinamento do modelo em cada conjunto da validação cruzada, foram feitas as previsões

com os dados de validação e a métrica IQR é calculada. Em seguida, o modelo é avaliado no conjunto de teste. Esse processo garante que o modelo final seja robusto, bem ajustado e capaz de generalizar adequadamente para novos cenários. O principal objetivo dessa abordagem é avaliar a capacidade de generalização dos modelos, ou seja, verificar como eles se comportam ao trabalhar com os dados não vistos durante o treinamento. Dessa forma, busca-se garantir que os modelos não apenas ajustem bem os dados de treinamento, mas também realizem previsões precisas em novos dados.

O modelo GBDT configurado para este trabalho utilizou o parâmetro *task* que foi definido como *train*, indicando que o objetivo é treinar o modelo com os dados fornecidos. Já o *boosting type* foi definido como GBDT, o que significa que o modelo utilizou o método tradicional de *boosting* por gradiente, onde as árvores são treinadas sequencialmente para corrigir os erros das anteriores.

A função de perda escolhida foi L1, definida no parâmetro *objective*, que corresponde ao erro absoluto médio (MAE). Essa função de perda é menos sensível a *outliers*, tornando o modelo mais robusto em relação a valores extremos. Para monitorar o desempenho durante o treinamento, o parâmetro *metric* inclui três métricas: L2 (erro quadrático médio, também conhecido como RMSE), L1 (erro absoluto médio) e *huber* uma função que combina características do erro absoluto e do quadrático, útil quando há *outliers* moderados [53].

A estrutura das árvores é controlada pelos parâmetros de número máximo de folhas e pela profundidade máxima permitida para cada árvore de decisão. O número máximo de folhas influencia diretamente a complexidade do modelo — quanto mais folhas, mais detalhes o modelo consegue capturar, mas isso também aumenta o risco de *overfitting*. A profundidade máxima de cada árvore, por sua vez, limita o número de divisões possíveis e contribui para a regularização do modelo [53].

O parâmetro *learning_rate* define a taxa de aprendizado do modelo, ou seja, o quanto cada nova árvore deve contribuir para corrigir os erros das anteriores [44]. Um valor mais baixo, como 0,05, torna o processo de aprendizado mais lento, porém mais cuidadoso, exigindo mais árvores para convergir, mas com menor risco de *overfitting*. Para isso, o número máximo de árvores a serem treinadas é controlado pelo parâmetro *num_boost_round*, que neste caso foi fixado em 100.

Para melhorar a generalização do modelo e evitar que ele aprenda padrões não representativos nos dados, foram utilizados os parâmetros *feature_fraction* e *bagging_fraction*. O *feature_fraction*, com valor de 0,8, faz com que, a cada árvore treinada, apenas 80% das variáveis sejam usadas de forma aleatória. Já o *bagging_fraction*, com valor de 0,7, controla a fração dos dados de treinamento utilizados para treinar cada árvore, promovendo diversidade no conjunto de árvores e reduzindo a variância do modelo. O parâmetro *bagging_freq*, definido como 2, indica que a amostragem (*bagging*) será realizada a cada duas iterações, aplicando o *bagging_fraction* com essa frequência [53].

Por fim, o parâmetro *early_stopping_rounds* foi definido como 10, o que significou a interrupção automática do treinamento caso, após 10 rodadas consecutivas, não houvesse melhora nas métricas de validação. Esse recurso foi importante para evitar desperdício computacional e também atuou como uma forma adicional de regularização, encerrando o processo antes que o modelo começasse a se ajustar demais aos dados de validação [44].

A Rede Neural *Multilayer Perceptron* (MLP), é composta por uma camada de entrada, uma ou mais camadas ocultas e uma camada final, denominada camada de saída. Cada camada, exceto a camada

de saída, possui um neurônio de viés e está totalmente conectada à próxima camada, ou seja, cada neurônio de uma camada se conecta a todos os neurônios da camada seguinte por meio de pesos ajustáveis [44].

O neurônio de viés funciona como um neurônio que sempre apresenta uma saída constante igual a 1, independentemente das entradas recebidas. A função do neurônio de viés é permitir que o modelo aprenda um termo constante, ou seja, um deslocamento na função de ativação dos neurônios da camada seguinte [44].

A arquitetura da rede neural utilizada neste trabalho consiste em três camadas densas, uma com 30 neurônios e duas com 10 neurônios cada, todas inicializadas com o método HeNormal, que é indicado para redes com função de ativação ReLU, pois ajuda a manter uma boa escala dos pesos no início do treinamento.

Cada camada densa foi seguida por uma função de ativação ReLU, que introduz não linearidade e ajuda a rede a aprender representações complexas dos dados. Em seguida, foi aplicada uma camada de normalização em *batch* (*BatchNormalization*), que normaliza as ativações da camada anterior, acelerando o treinamento e contribuindo para a estabilidade da rede. Para evitar o *overfitting*, foi inserida uma camada de *dropout* com taxa de 11%, que desativa aleatoriamente essa fração dos neurônios durante o treinamento, forçando a rede a não depender excessivamente de neurônios específicos [44].

A camada de saída é uma camada densa com apenas um neurônio e ativação linear, adequada para problemas de regressão onde se prevê um valor contínuo. O modelo foi compilado com o otimizador Adam, configurado com uma taxa de aprendizado muito baixa de aproximadamente 0,000418, o que proporciona um ajuste cuidadoso e estável dos pesos durante o treinamento. A função de perda escolhida foi o erro absoluto médio, apropriada para minimizar erros médios e sendo robusta a *outliers*, enquanto a métrica de avaliação utilizada é o erro quadrático médio.

Para controle do treinamento, foi aplicado o mecanismo de parada antecipada (*EarlyStopping*), monitorando a perda de validação com uma paciência de 10 épocas, o que interrompe o treinamento caso o modelo não apresente melhoria nessa métrica por 10 ciclos consecutivos, restaurando os pesos do melhor modelo encontrado.

Os dados foram normalizados utilizando a técnica de normalização por soma absoluta, onde cada característica é dividida pela soma dos valores absolutos das características do evento. A normalização aplicada aos valores de energia registrados nos anéis do calorímetro é descrita pela seguinte equação:

$$r'_k = \frac{r_k}{|\sum_{i=1}^n r_i|}, \quad \forall k \in \{1, \dots, n\}, \quad (4.6)$$

onde:

r'_k : É o valor normalizado;

r_k : Valor da energia registrada nos *Standard Rings* e nos *Quarter Rings* do calorímetro, antes da normalização. Para todo k pertencente ao conjunto de 1 até 100;

$|\sum_{i=1}^n r_i|$: É a soma das energias de todos os anéis do evento.

Essa normalização tem como principal objetivo tornar os valores de entrada comparáveis entre diferentes eventos, independentemente da magnitude absoluta das energias registradas. Ao dividir cada valor r_k pela soma total das energias de todos os anéis, obtém-se a proporção relativa de energia associada a cada anel. Isso significa que a rede neural não será influenciada por eventos com maiores valores absolutos de energia e, sim, pela distribuição da energia entre os anéis.

O uso do valor absoluto na soma evita que o acúmulo de ruído negativo ao longo do eixo distorça a representação física dos dados normalizados e comprometa a qualidade das decisões do modelo. A normalização favorece a estabilidade e a eficiência do treinamento, pois os algoritmos de aprendizado de máquina geralmente apresentam melhor desempenho e convergência quando os dados de entrada estão em escalas semelhantes.

Diversas abordagens de normalização foram avaliadas, incluindo a padronização *z-score*, a normalização Min-Max e o escalonamento robusto (*Robust Scaling*). No entanto, os resultados obtidos não apresentaram variações expressivas entre essas técnicas. Dessa forma, optou-se pela estratégia baseada na soma absoluta das energias dos anéis, a qual já é amplamente utilizada no *NeuralRinger* [35].

Outra ferramenta utilizada na análise de desempenho foi o gráfico de resolução, que apresenta histogramas da distribuição do erro relativo entre a energia predita (E_{fast}) e a energia verdadeira (E_{truth}) medida pelo calorímetro. O erro relativo é calculado conforme a seguinte expressão:

$$\text{Erro relativo} = \left(\frac{E_{\text{fast}}}{E_{\text{truth}}} \right) - 1. \quad (4.7)$$

Para avaliar quantitativamente os modelos calibrados, utilizou-se o ganho médio percentual, métrica que quantifica a melhoria no desempenho de uma estratégia de calibração em relação a uma configuração de referência — neste caso, representada pelos resultados obtidos sem calibração. Esse ganho é calculado a partir da média dos ganhos percentuais obtidos em diferentes faixas de pseudorapidez e energia, permitindo uma avaliação global da eficácia da abordagem proposta.

Com o objetivo de compreender melhor os *Quarter Rings* e sua relevância na descrição das assimetrias do detector, foram gerados gráficos do perfil médio de energia depositada em cada anel do calorímetro, tanto para os *Standard Rings* quanto para os *Quarter Rings*. Esses gráficos mostram como a energia se distribui ao longo dos diferentes anéis do detector, permitindo identificar padrões de simetria ou assimetria na deposição de energia.

Além disso, os gráficos de distribuição da energia fornecem uma representação visual mais intuitiva da forma como a energia é depositada em cada evento, evidenciando sua dispersão à medida que nos afastamos da *Hotcell*. Essa abordagem também facilita a identificação de possíveis assimetrias na distribuição de energia entre os anéis. Para essa análise, eventos consecutivos da camada EM2 foram agrupados, com o intuito de verificar a presença ou ausência de assimetrias nos anéis.

5 Resultados

Este trabalho investigou a calibração de energia do ATLAS utilizando dois métodos principais de aprendizado supervisionado: o *Gradient Boosted Decision Tree* (GBDT) e as Redes Neurais do tipo *Multilayer Perceptron* (MLP). Nos dois casos, a informação percorre o modelo em apenas uma direção, sendo processada passo a passo, desde a entrada até a saída, sem retornar a etapas anteriores

No caso do GBDT, múltiplas árvores de decisão são combinadas de forma sequencial, com cada nova árvore treinada para corrigir os erros das anteriores, o que resulta em um modelo robusto e preciso [41]. Da mesma forma, a Rede Neural *Feedforward* é composta por camadas de neurônios organizadas de forma que a informação flui da entrada para a saída, passando por duas camadas ocultas [42]. Ambos os métodos são amplamente utilizados em tarefas de regressão devido à sua flexibilidade e alto desempenho.

A análise dos dados provenientes dos calorímetros revela que as energias depositadas nas células do detector apresentam distribuições assimétricas. Essa característica é evidente com a implementação dos *Quarter Rings*.

As Figuras 18 e 19 apresentam gráficos de barras de erro que representam os perfis médios de energia depositada para os *Standard Rings* e *Quarter Rings*, respectivamente. Em ambos os gráficos, cada ponto corresponde à média da energia depositada nos métodos apresentados, enquanto as barras de erro indicam o desvio padrão, refletindo a variabilidade entre os eventos. O eixo horizontal representa os índices dos anéis — sendo 100 no caso dos *Standard Rings* e 379 para os *Quarter Rings*, nas diferentes regiões dos calorímetros. O eixo vertical exibe a energia média em escala logarítmica, permitindo visualizar variações que abrangem várias ordens de grandeza.

Os perfis evidenciam que a maior parte da energia é depositada na camada EM2. Observa-se que, logo no início dessa camada, ocorrem picos de energia maiores, seguidos de uma rápida queda à medida que se afastam os anéis centrais. Esse comportamento é característico do espalhamento lateral das cascatas eletromagnéticas geradas pelas partículas no calorímetro. Esse tipo de visualização é importante pois revela diferenças no comportamento da deposição de energia entre as camadas.

A Figura 20 ilustra a distribuição assimétrica da energia depositada no calorímetro do evento 15, que foi escolhido apenas para exemplificação — qualquer outro evento poderia ter sido utilizado com o mesmo propósito, obtido pela técnica dos *Quarter Rings* especificamente na camada EM2. Observa-se uma concentração significativamente maior de energia no anel zero, que corresponde à região central em torno da célula com maior energia depositada, conhecida como *Hotcell*. Os anéis subsequentes representam as regiões concêntricas ao redor dessa célula central. À medida que nos afastamos do anel inicial, nota-se uma diminuição progressiva e assimétrica na energia depositada entre os anéis.

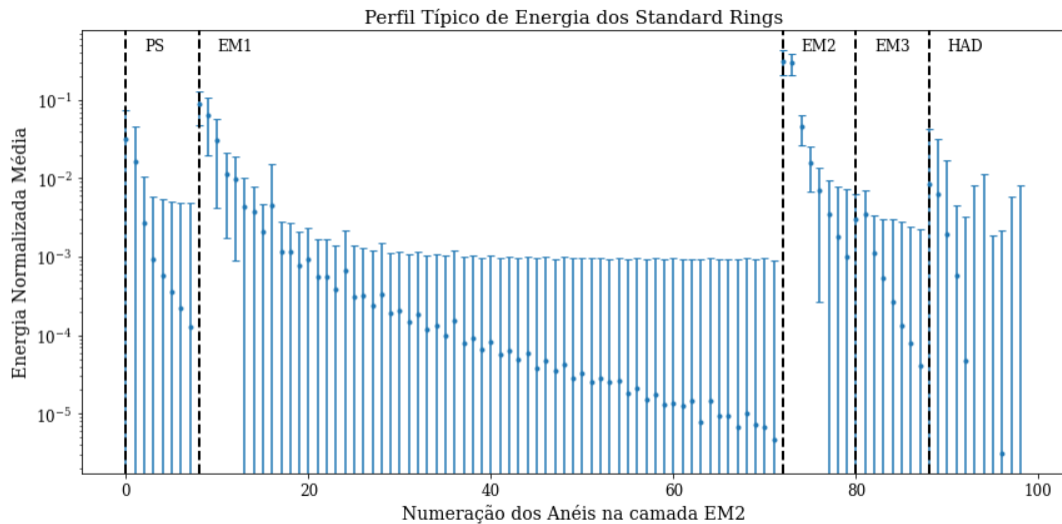


Figura 18 – Gráfico dos perfis de energia depositada dos *Standard Rings*




Figura 19 – Gráfico dos perfis de energia depositada dos *Quarter Rings*

Como cada conjunto de 4 *Quarter Rings* forma um *Standard Ring*, seria esperado que, em um evento simétrico, os grupos de anéis 1–4, 5–8, e assim por diante, apresentassem deposições de energia equivalentes. No entanto, observa-se uma variação considerável entre os valores, evidenciando a assimetria na distribuição da energia entre os anéis. Essa assimetria se manifesta visualmente nas diferenças de altura entre as barras, refletindo o perfil assimétrico do chuveiro eletromagnético.

Esse comportamento indica que os anéis mais distantes da *hotcell* tendem a contribuir menos significativamente. Portanto, o uso de todos os anéis pode ser redundante em algumas abordagens, especialmente naquelas que envolvem redução de dimensionalidade ou seleção de atributos, uma vez que os anéis periféricos têm impacto limitado na representação do padrão de deposição de energia.

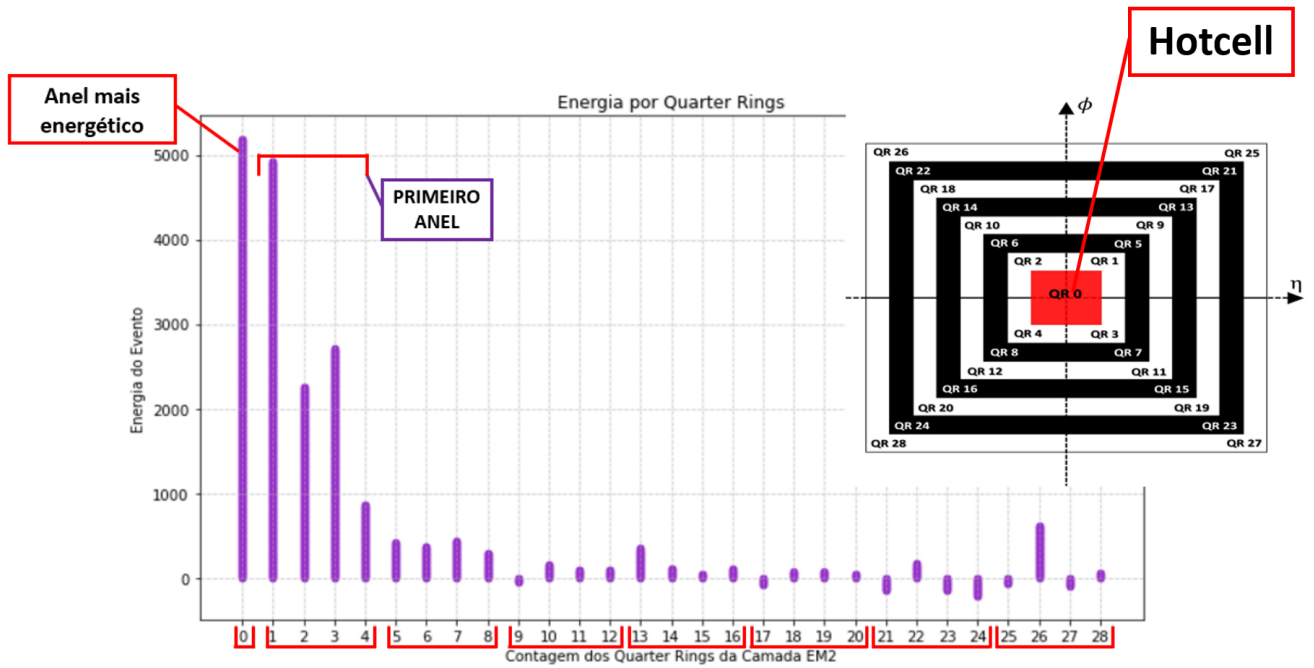


Figura 20 – Gráfico da distribuição da energia depositada de forma assimétrica por anel na camada EM2, no evento 15.

As Figuras 21 e 22 mostram a dispersão do fluxo de energia entre diferentes *Quarter Rings* na camada EM2, utilizando os anéis mais próximos do anel central (QR1, QR2, QR3 e QR4), conforme indicado na Figura 12. Esses gráficos evidenciam o desequilíbrio na deposição de energia nas direções η e ϕ , refletindo a assimetria presente nos chuveiros eletromagnéticos.

Na Figura 21, o eixo horizontal representa a diferença de energia entre os quadrantes QR1 e QR3, enquanto o eixo vertical mostra a diferença entre QR2 e QR4. Já na Figura 22, a diferença entre QR1 e QR2 está representada no eixo horizontal, e a diferença entre QR3 e QR4 no eixo vertical. Essas representações permitem visualizar a distribuição assimétrica da energia nos eventos, destacando possíveis desvios em relação a uma configuração idealmente simétrica.

Para obter os dados desta figura, foi calculada a diferença em energia entre anéis vizinhos, dada pela equação abaixo.

1 . A diferença de energia na direção positiva de η e Φ é dada por:

Para η quando $\Phi = \Phi^+$:

$$\Delta E(\eta|\Phi = \Phi^+) = E(QR1) - E(QR2), \quad (5.1)$$

Para Φ quando $\eta = \eta^+$:

$$\Delta E(\Phi|\eta = \eta^+) = E(QR1) - E(QR3), \quad (5.2)$$

2 . A diferença de energia na direção negativa de η e Φ é dada por:

Para η quando $\Phi = \Phi^-$:

$$\Delta E(\eta|\Phi = \Phi^-) = E(QR3) - E(QR4), \quad (5.3)$$

Para Φ quando $\eta = \eta^-$:

$$\Delta E(\eta|\eta = \eta^-) = E(QR2) - E(QR4), \quad (5.4)$$

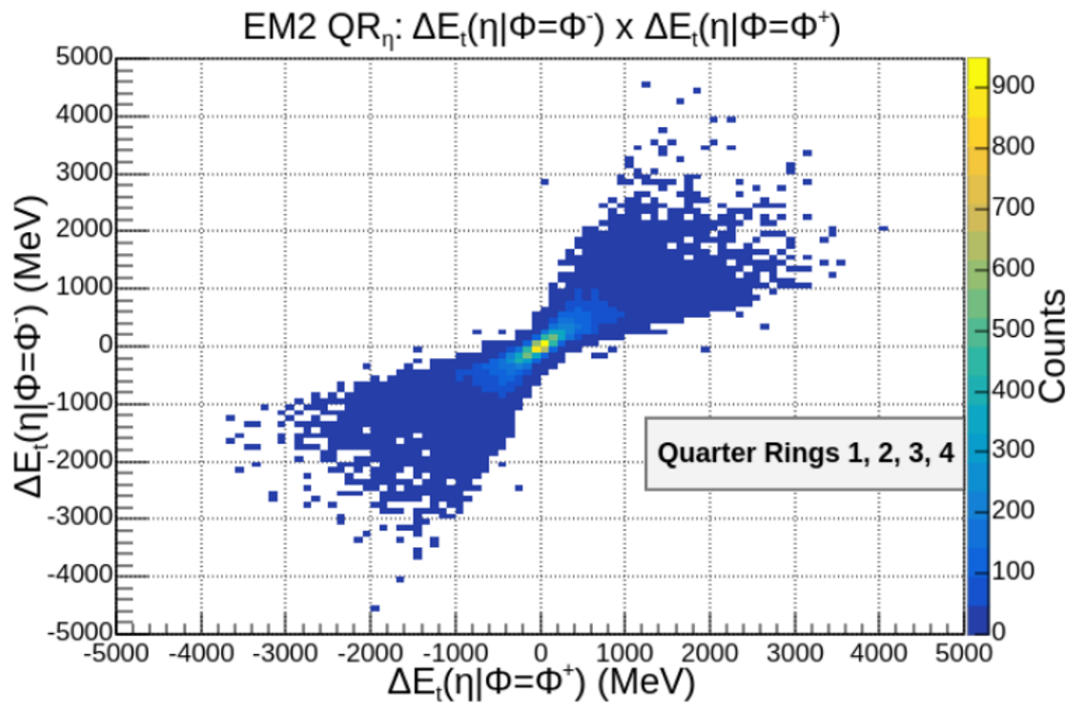


Figura 21 – Assimetria do fluxo de energia para um conjunto de *Quarter Rings* na camada EM2, em relação a η .

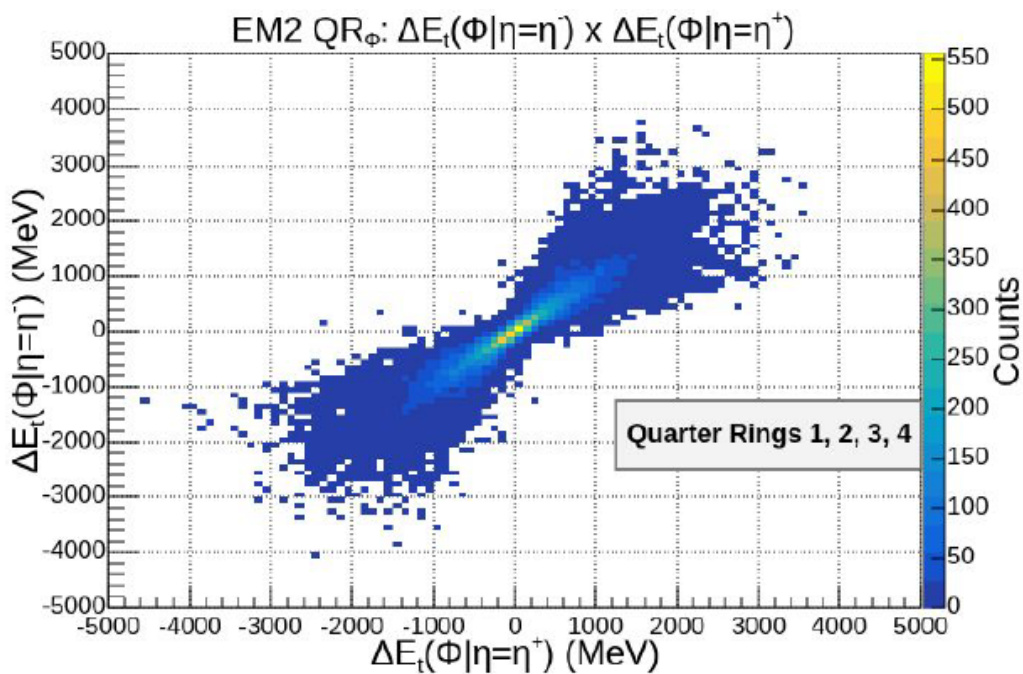


Figura 22 – Assimetria do fluxo de energia para um conjunto de *Quarter Rings* na camada EM2 em relação a Φ .

Portanto, se o perfil do chuveiro fosse simétrico, as diferenças de energia dos *Quarter Rings* deveriam se concentrar em torno de zero, indicando equilíbrio na deposição de energia entre os quadrantes. No entanto, conforme ilustrado nas Figuras 21 e 22, observa-se uma dispersão significativa em torno da

origem, o que reforçam a presença de assimetrias. Esses resultados indicam que os *Quarter Rings* são sensíveis o suficiente para capturar essas assimetrias na distribuição de energia.

Como exemplo, considere o evento ilustrado na Figura 23, no qual a diferença entre QR2 E QR4 é zero, enquanto a diferença entre QR1 E QR3 é de -1 GeV, o sinal negativo indica a região onde a energia está depositada. Como o ponto não está no zero em QR1 - QR3, essa diferença evidencia um desequilíbrio na distribuição de energia, caracterizando um evento assimétrico, com maior concentração nos quadrantes QR1 - QR3.

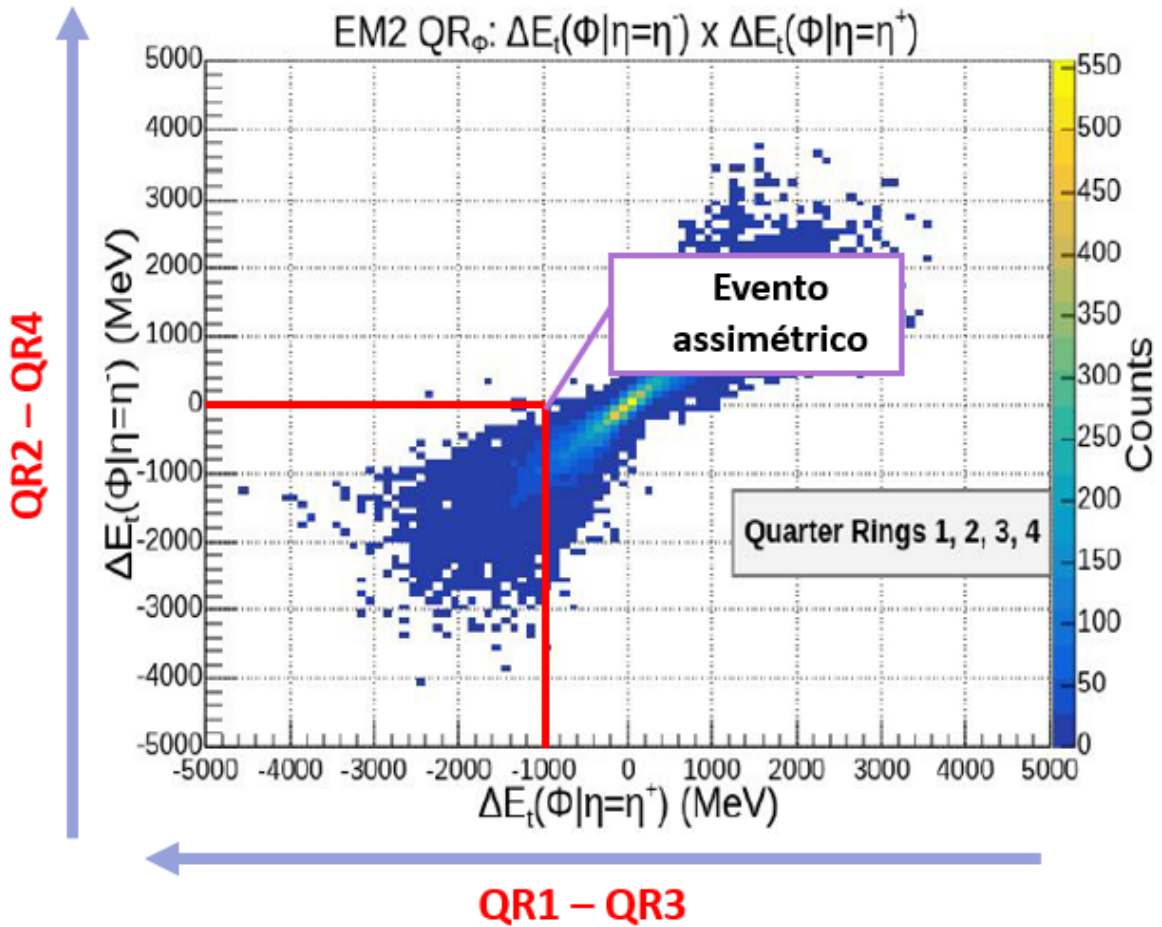


Figura 23 – Assimetria do fluxo de energia para um conjunto de *Quarter Rings* na camada EM2 em relação a η .

Os *Quarter Rings*, oferecem uma representação mais granular da distribuição espacial da energia no calorímetro, são capazes de capturar variações sutis no perfil dos chuveiros eletromagnéticos, evidenciando assimetrias que seriam pouco perceptíveis com as representações dos *Standard Rings*. A sensibilidade a essas diferenças, especialmente nas direções η e Φ , reforça o potencial dos *Quarter Rings* como uma ferramenta eficaz na melhoria da resolução e precisão em tarefas de reconstrução de energia. Assim, a combinação dessa representação com técnicas avançadas de aprendizado de máquina, como GBDT e rede neural MLP, são uma abordagem promissora para a calibração de energia em experimentos de alta energia, como o ATLAS.

5.1 Resultados da GBDT

Os resultados da GBDT foram avaliados utilizando gráficos do Intervalo Interquartil (IQR), métrica que mede a dispersão da razão entre a energia estimada (E_{Fast}) e a energia verdadeira (E_{Truth}), enquanto o eixo horizontal exibe a pseudorapidez η . Além disso, a métrica também avalia a dispersão da razão entre a E_{Fast} e a E_{Truth} , enquanto o eixo horizontal exibe a energia.

Para avaliar a consistência e a capacidade de generalização do modelo da GBDT, foi aplicada a validação cruzada k-fold com k=5. Esse método permitiu dividir o conjunto de treinamento em cinco partições, garantindo que cada uma delas fosse utilizada alternadamente para validação e treinamento.

5.1.1 Análise pelo Método dos Dados Brutos sem a Presença de *Pile-Up*

A Figura 24 mostra a variação do IQR da distribuição do fator de calibração α em função da posição no calorímetro, traduzida pela pseudorapidez η . A figura mostra o resultado para dados sem *pile-up*, abrangendo o intervalo de energia de 10 GeV a 3.000 GeV. Foram analisadas duas configurações de entrada: *Standard Rings* e *Quarter Rings*, sem extração de atributos nos dados.




Figura 24 – Comportamento do IQR do fator α , em função de η , sem a presença de *pile-up*.

Após a calibração, conforme mostrado na Figura 24 observamos uma redução no espalhamento de α , o que indica melhorias significativas em relação aos dados não calibrados. Os métodos utilizando GBDT demonstram um desempenho superior ao método sem calibração, evidenciando que o GBDT captura de forma mais eficaz as variações na resposta do detector.

Pode-se observar que o desempenho dos *Quarter Rings* foi ligeiramente superior ao dos *Standard Rings* nas faixas de pseudorapidez apresentadas na Tabela 4. Nas demais faixas de η , ambos apresentaram desempenhos semelhantes.

Tabela 4 – Desempenho dos *Quarter Rings* em diferentes faixas de pseudorapidez

Faixa de η	Desempenho dos <i>Quarter Rings</i>
0,6 – 0,8	Superior
1,52 – 1,8	Superior
1,8 – 2,0	Superior
2,2 – 2,5	Superior
Demais faixas	Semelhante

A Figura 25 mostra o comportamento do IQR em função da energia, sem a presença de *pile-up*. O gráfico mostra o comportamento do IQR da razão entre a E_{Fast} e a E_{Truth} em função da energia das partículas, considerando diferentes métodos de calibração.




Figura 25 – Comportamento do IQR do fator α , em função da energia, sem a presença de *pile-up*.

Observou-se que, no gráfico do IQR em função da energia, os *Quarter Rings* apresentaram desempenho ligeiramente superior aos *Standard Rings* nas faixas de energia apresentadas na Tabela 5. Nas demais faixas, os valores foram muito próximos, indicando desempenho semelhante das duas configurações.

Tabela 5 – Desempenho dos *Quarter Rings* em diferentes faixas de energia

Faixa de energia [GeV]	Desempenho dos <i>Quarter Rings</i>
50 – 70	superior
70 – 100	superior
100 – 150	superior
150 – 200	superior
Demais faixas	Semelhante

A aplicação da calibração resultou em uma melhora na estimativa do parâmetro α . A Figura 26 apresenta o gráfico de resolução para a faixa de energia entre 40 e 50 GeV, permitindo visualizar e comparar o desempenho dos diferentes métodos de estimativa analisados. Observa-se que a calibração contribuiu para a redução da dispersão relativa dos valores estimados, especialmente no caso dos *Quarter Rings*, que apresentaram menor dispersão nessa faixa de energia.

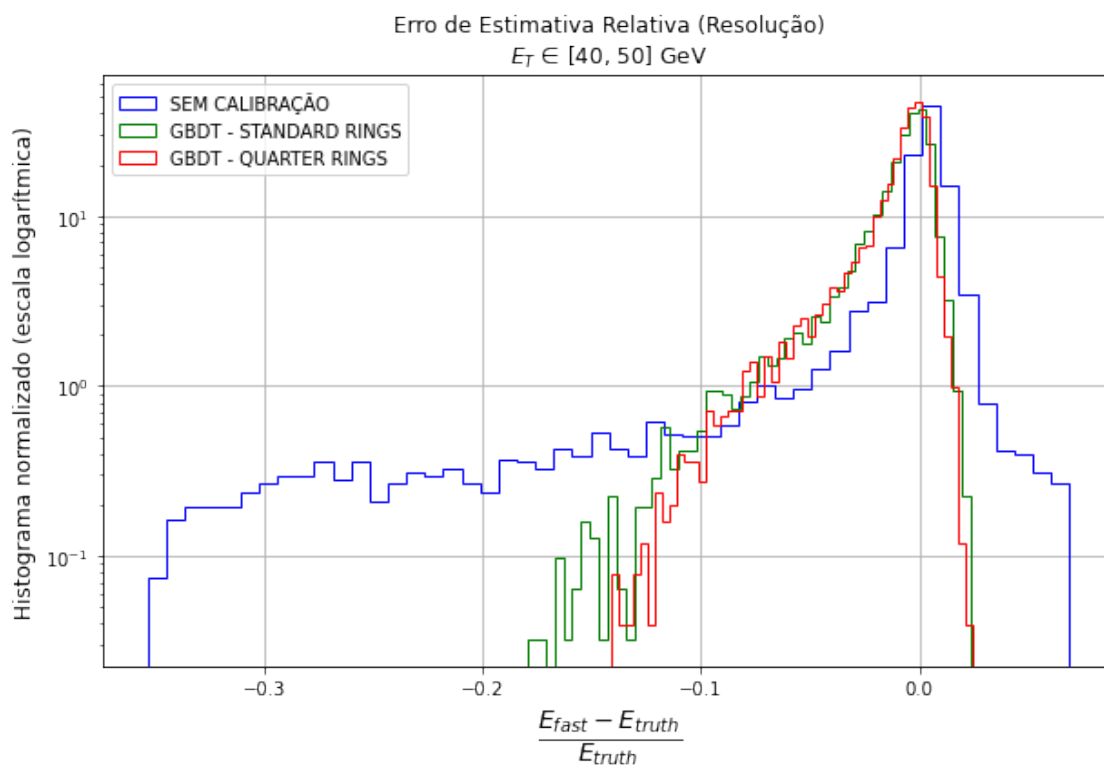


Figura 26 – Gráfico de resolução em função da energia na faixa de 40 a 50 GeV, sem a presença de *pile-up*.

O cálculo do ganho médio percentual foi utilizado para medir a diferença relativa entre os valores dos dados não calibrados e dos dados onde a calibração foi realizada, sem a presença de *pile-up*. Nas tabelas 6 e 7, podemos ver o ganho médio de todas as faixas de energia das abordagens dos *Standard Rings* e dos *Quarter Rings* em relação aos dados não calibrados, tanto em função de η quanto em função da energia.

Tabela 6 – Ganho médio percentual do IQR para as configurações analisadas, em função de η , sem a presença de *pile-up*

Configuração	Standard Rings	Quarter Rings
Dados Brutos	14,91%	15,82%

Tabela 7 – Ganho médio percentual do IQR para as configurações analisadas, em função da energia, sem a presença de *pile-up*

Configuração	Standard Rings	Quarter Rings
Dados Brutos	13,47%	13,79%

Observa-se que ambas as abordagens — *Standard Rings* e *Quarter Rings* — resultaram em melhorias consideráveis na qualidade das estimativas. Em função de η , Tabela 6, o ganho médio percentual foi de aproximadamente 14,91% com o uso dos *Standard Rings* e de aproximadamente 15,82% com os *Quarter Rings*, indicando que a substituição dos *Standard Rings* pelos *Quarter Rings* contribuiu para uma ligeira redução adicional na variabilidade das previsões.

De forma semelhante, ao analisar os resultados em função da energia (Tabela 7), verifica-se um ganho médio de aproximadamente 13,47% para os *Standard Rings* e de aproximadamente 13,79% para os *Quarter Rings*. Embora os valores sejam ligeiramente inferiores aos observados na análise por η , os ganhos ainda demonstram que a calibração é eficaz em reduzir a dispersão das estimativas de energia.

Em ambos os casos, os *Quarter Rings* apresentaram desempenho levemente superior aos *Standard Rings*, sugerindo que a reorganização espacial dos anéis fornece uma representação mais informativa dos dados de entrada. Essa diferença, embora sutil, reforça a relevância da estrutura dos atributos utilizados no processo de calibração.

5.1.2 Análise pelo Método dos Dados Brutos com a Presença de *Pile-Up*

A Figuras 27 e 28 permitem avaliar o impacto do *pile-up* no processo de calibração, que foi realizada com *Standard Rings* e *Quarter Rings*. Assim como no caso das Figuras 24 e 25, não houve tratamento prévio ou extração de atributos. Os resultados indicam que a calibração apresenta uma certa robustez à presença de *pile-up*.




Figura 27 – Comportamento do IQR do fator α , em função da η , com *pile-up* $\langle \mu \rangle$ na faixa de 25 a 52.

Analisando o gráfico da Figura 27 pode-se observar que o desempenho dos *Quarter Rings* foi superior ao dos *Standard Rings* nas faixas de pseudorapidez apresentadas na Tabela 8. Nas demais faixas de η , ambos apresentaram desempenhos semelhantes.

Tabela 8 – Desempenho dos *Quarter Rings* em diferentes faixas de pseudorapidez

Faixa de η	Desempenho dos <i>Quarter Rings</i>
0,6 – 0,8	Superior
1,37 – 1,52	Superior
1,52 – 1,8	Superior
Demais faixas	Semelhante

Na Figura 28 observa-se que o desempenho dos *Quarter Rings* apresentou uma piora de desempenho na presença de *pile-up*, quando comparado ao caso sem *pile-up*. Esse resultado indica um pequeno retrocesso na capacidade de reduzir a dispersão das estimativas. Ainda assim, mesmo com essa limitação, os *Quarter Rings* mantiveram um desempenho semelhante ao dos *Standard Rings*, sem se destacarem em faixa alguma específica.

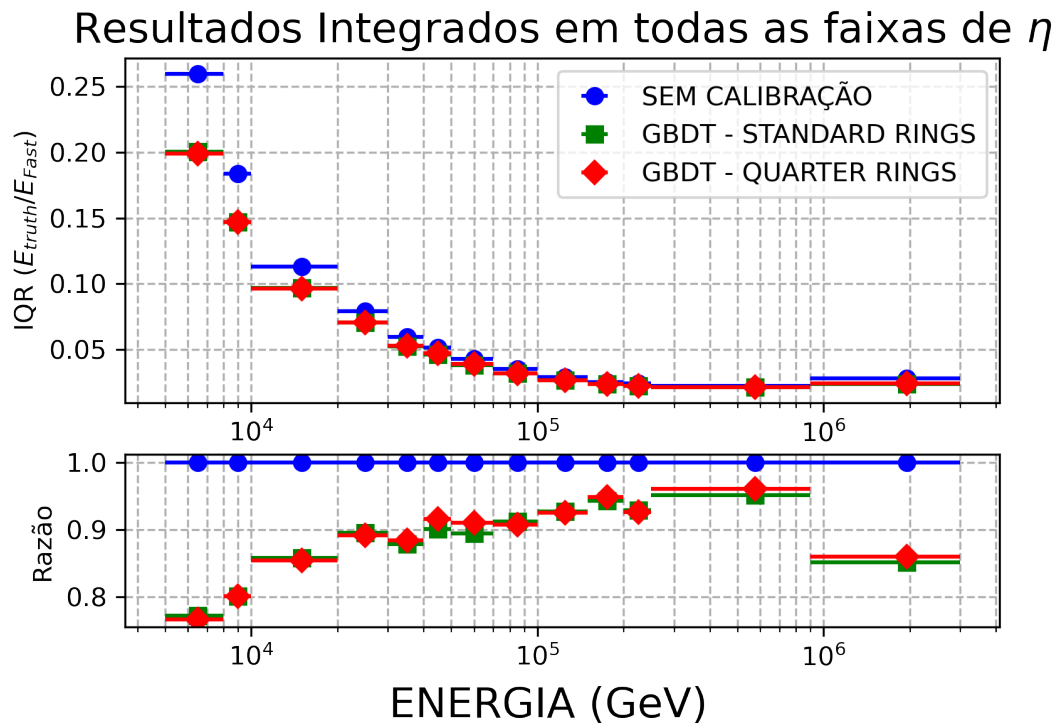


Figura 28 – Comportamento do IQR do fator α , em função da energia, com $pile-up < \mu >$ na faixa de 25 a 52.

A calibração proporcionou uma melhoria na estimativa do parâmetro α . A Figura 29 exibe o gráfico da resolução correspondente à faixa de energia entre 40 e 50 GeV. Nota-se que a aplicação da calibração reduziu a dispersão relativa das estimativas, sendo particularmente evidente na configuração dos *Quarter Rings*, que apresentaram a menor dispersão nesse intervalo de energia.

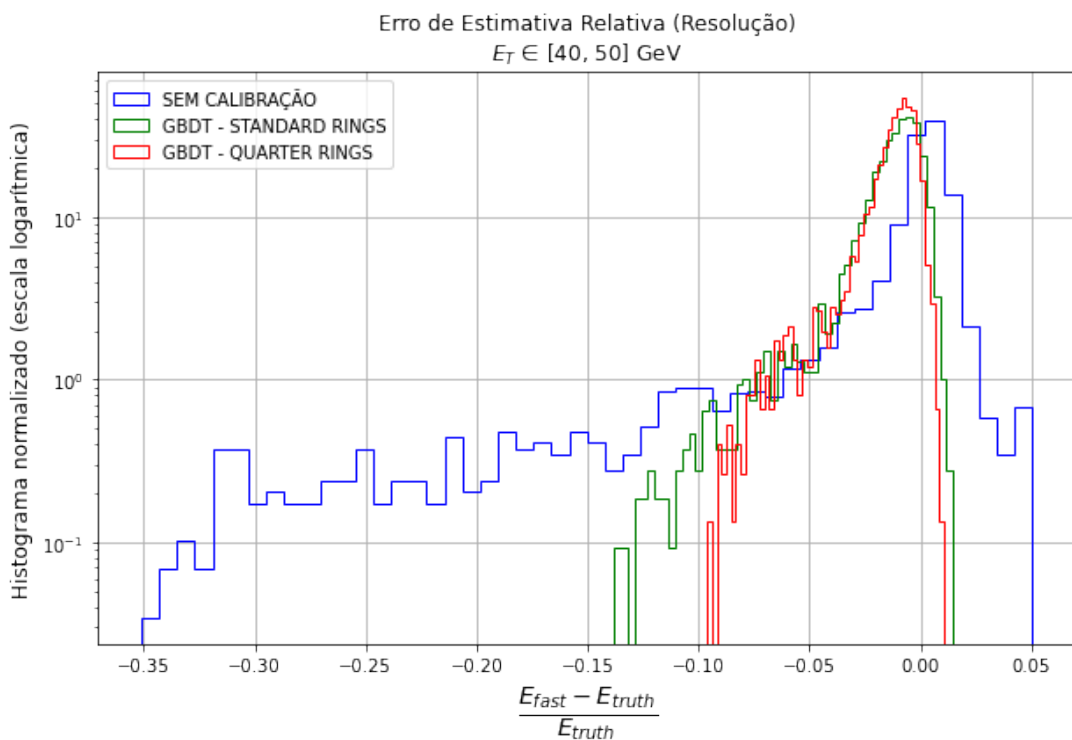


Figura 29 – Gráfico de resolução em função da energia na faixa de 40 a 50 GeV, considerando o efeito *pile-up*.

As Tabelas 9 e 10 apresentam o ganho percentual médio do IQR obtido após a calibração dos dados na presença de *pile-up*, em relação aos dados não calibrados. Esses valores indicam a capacidade dos métodos calibrados de reduzir a dispersão das estimativas mesmo diante das dificuldades impostas pelo *pile-up*.

Tabela 9 – Ganho médio percentual do IQR para as configurações analisadas, em função de η , com a presença de *pile-up*

Configuração	Standard Rings	Quarter Rings
<i>Dados Brutos</i>	13,44%	13,49%

Tabela 10 – Ganho médio percentual do IQR para as configurações analisadas, em função da energia, com a presença de *pile-up*

Configuração	Standard Rings	Quarter Rings
<i>Dados Brutos</i>	11,49%	11,18%

Na análise em função de η , Tabela 9, observa-se que tanto os *Standard Rings* quanto os *Quarter Rings* apresentam ganhos médios muito próximos, aproximadamente 13,44% e 13,49%, respectivamente. Essa semelhança sugere que, sob a influência do *pile-up*, ambas as configurações mantêm uma eficiência comparável na melhoria da precisão das estimativas.

Por outro lado, na análise em função da energia, Tabela 10, os ganhos médios apresentam valores ligeiramente menores, aproximadamente 11,49% para os *Standard Rings* e de aproximadamente 11,18% para os *Quarter Rings*. Embora os *Quarter Rings* apresentem um desempenho ligeiramente inferior nesse caso, a diferença é pequena, indicando que ambas as abordagens ainda conseguem mitigar parcialmente os efeitos do *pile-up* sobre a dispersão das predições.

De modo geral, os resultados evidenciam que a presença de *pile-up* reduz o ganho percentual obtido pela calibração em relação ao cenário sem *pile-up*, mas tanto os *Standard Rings* quanto os *Quarter Rings* continuam a oferecer melhorias relevantes e semelhantes na resolução das estimativas, reafirmando a robustez dos métodos calibrados.

5.1.3 Análise pelo Método da Extração de Variáveis Energéticas e Assimétricas sem a Presença de *Pile-Up*

As Figuras 30 e 31 apresentam uma abordagem alternativa para os dados de entrada, na qual foi aplicado um processo de extração de atributos com o objetivo de reduzir a quantidade de características fornecidas à GBDT, sem a aplicação do logaritmo da soma das energias do calorímetro.

Resultados Integrados em todas as faixas de energia

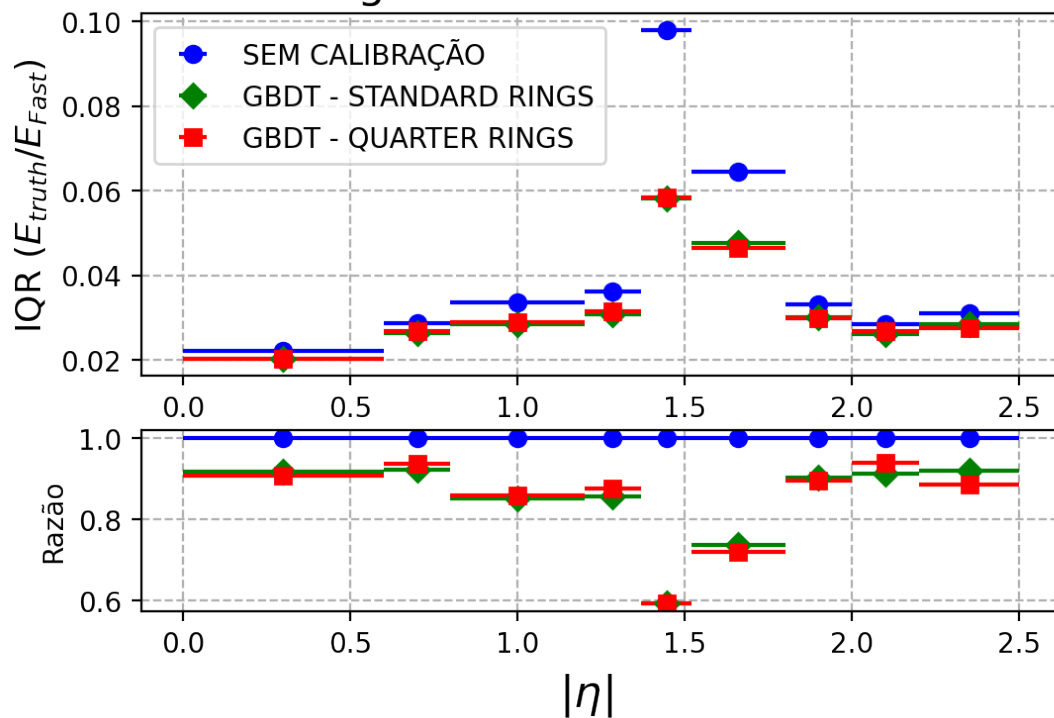


Figura 30 – Comportamento do IQR do fator α , em função de η . Os dados passaram por extração de atributos, sem a presença de *pile-up*.

Após a calibração, conforme mostrado na Figura 30, observamos uma redução no espalhamento de α , o que indica melhorias significativas em relação aos dados não calibrados. Os métodos utilizando GBDT demonstram um desempenho superior ao método sem calibração, evidenciando que o GBDT captura de forma mais eficaz as variações na resposta do detector. Pode-se observar que o desempenho dos *Quarter Rings* foi superior ao dos *Standard Rings* nas faixas de pseudorapidez apresentadas na Tabela 11. Nas demais faixas de η , ambos apresentaram desempenhos semelhantes.

Tabela 11 – Desempenho dos *Quarter Rings* em diferentes faixas de pseudorapidez

Faixa de η	Desempenho dos <i>Quarter Rings</i>
0 – 0,6	Superior
1,52 – 1,8	Superior
1,8 – 2,0	Superior
2,2 – 2,5	Superior
Demais faixas	Semelhante

Observou-se que, no gráfico do IQR em função da energia, Figura 31, os *Quarter Rings* apresentaram desempenho ligeiramente superior aos *Standard Rings* nas faixas de energia entre apresentadas na Tabela 12. Nas demais faixas, os valores foram muito próximos, indicando desempenho semelhante entre as duas configurações. A análise do gráfico de resolução, Figura 32, reforça essa vantagem, especialmente na faixa de 40 a 50 GeV.




Figura 31 – Comportamento do IQR do fator α , em função da energia. Os dados passaram por extração de atributos, sem a presença de *pile-up*.

Tabela 12 – Desempenho dos *Quarter Rings* em diferentes faixas de energia

Faixa de energia [GeV]	Desempenho dos <i>Quarter Rings</i>
70 – 100	Superior
100 – 150	Superior
150 – 200	Superior
Demais faixas	Semelhante

No contexto deste estudo, o objetivo é avaliar a melhoria do IQR após a aplicação das diferentes configurações de calibração. As métricas de ganho médio percentual indicam o quanto as configurações propostas, *Standard Rings* e *Quarter Rings*, foram capazes de melhorar o desempenho do IQR em relação à configuração sem calibração.

As Tabelas 13 e 14 apresentam os ganhos médios percentuais do IQR obtidos após a aplicação das configurações de calibração com extração de atributos, na ausência de *pile-up*. O objetivo dessa análise é quantificar a melhoria na dispersão das estimativas do parâmetro α , comparando os resultados calibrados com os dados não calibrados.




Figura 32 – Gráfico de resolução em função da energia na faixa de 40 a 50 GeV. Os dados passaram por extração de atributos, sem a presença de *pile-up*.

Tabela 13 – Ganho médio percentual do IQR para as configurações analisadas, em função de η , sem a presença de *pile-up*

Configuração	Standard Rings	Quarter Rings
Com Extração de Atributos	15,38%	15,33%

Tabela 14 – Ganho médio percentual do IQR para as configurações analisadas, em função da energia, sem a presença de *pile-up*

Configuração	Standard Rings	Quarter Rings
Com Extração de Atributos	15,30%	14,95%

Na Tabela 13, que mostra os ganhos médios em função da pseudorapidez (η), observa-se que tanto os *Standard Rings* quanto os *Quarter Rings* tiveram melhorias bastante próximas, com ganhos médios de aproximadamente 15,38% e 15,33%, respectivamente. Isso indica que, quando a extração de atributos é aplicada, ambas as configurações são igualmente eficazes na redução da dispersão das estimativas ao longo das diferentes regiões de η .

De maneira semelhante, a Tabela 14 apresenta os ganhos médios em função da energia 15,30% para os *Standard Rings* e 14,95% para os *Quarter Rings*. Embora o desempenho dos *Standard Rings* tenha sido superior nessa métrica, a diferença é pequena, sugerindo que os *Quarter Rings* continuam sendo uma alternativa competitiva mesmo após a redução da dimensionalidade imposta pela extração de atributos. Esses resultados reforçam que a combinação da calibração com técnicas de extração de atributos mantém a eficácia dos modelos em melhorar a precisão das estimativas, reduzindo a dispersão. Além disso, a pequena diferença entre as abordagens confirma que ambas são robustas e funcionam bem nesse cenário.

5.1.4 Análise pelo Método da Extração de Variáveis Energéticas e Assimétricas com a Presença de *Pile-Up*

A Figuras 33 e 34 permitem avaliar o impacto do efeito *pile-up* no processo de calibração, que foi realizada com *Standard Rings* e *Quarter Rings*. Assim como no caso das Figuras 30 e 31, houve extração de atributos. Os resultados indicam que a calibração apresenta uma certa robustez à presença de *pile-up*.

Resultados Integrados em todas as faixas de energia

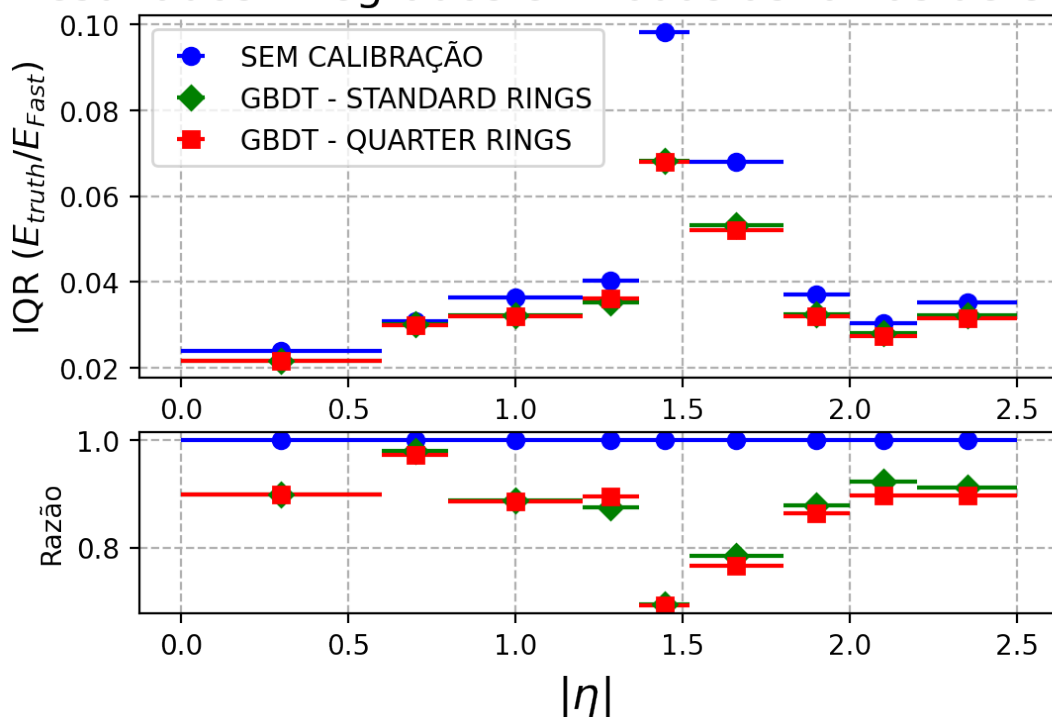


Figura 33 – Comportamento do IQR do fator α , em função de η . Os dados passaram por extração de atributos, com a presença de *pile-up*.

Analisando o gráfico da Figura 33, pode-se observar que o desempenho dos *Quarter Rings* foi superior ao dos *Standard Rings* em quase todas as faixas de pseudorapidez, conforme apresentadas na Tabela 15.

Tabela 15 – Desempenho dos *Quarter Rings* em diferentes faixas de pseudorapidez

Faixa de η	Desempenho dos <i>Quarter Rings</i>
0 – 0,6	Superior
0,6 – 0,8	Superior
0,8 – 1,2	Superior
1,52 – 1,8	Superior
1,8 – 2,0	Superior
2,0 – 2,2	Superior
2,2 – 2,5	Superior
Demais faixas	Semelhante

A Figura 34 mostra que o desempenho dos *Quarter Rings* sofreu uma leve piora na presença de *pile-up*, especialmente nas faixas de energia em que, no cenário sem *pile-up*, eles haviam se destacado em

relação aos *Standard Rings*. A única exceção foi a faixa entre 30 e 40 GeV, na qual os *Quarter Rings*, que anteriormente apresentavam desempenho inferior, passaram a superar levemente os *Standard Rings*. Esse resultado indica um pequeno retrocesso geral na capacidade dos *Quarter Rings* de reduzir a dispersão das estimativas na presença de *pile-up*. Ainda assim, o fato de manterem um desempenho semelhante ao dos *Standard Rings* em quase todas as faixas evidencia a robustez da abordagem frente aos efeitos adversos do *pile-up*.




Figura 34 – Comportamento do IQR do fator α , em função da energia. Os dados passaram por extração de atributos, com a presença de *pile-up*.

A Figura 35 apresenta o gráfico de resolução do modelo na faixa de energia entre 40 e 50 GeV. A análise revela que os *Quarter Rings* tiveram o melhor desempenho, contribuindo para estimativas mais estáveis e confiáveis. Esses resultados reforçam a eficácia e a robustez dos *Quarter Rings* como uma alternativa promissora para a reconstrução da energia nessa faixa.

As Tabelas 16 e 17 apresentam os ganhos médios percentuais do IQR obtidos após a aplicação das estratégias de calibração nas configurações com extração de atributos, considerando a presença de *pile-up*. O objetivo é quantificar a melhoria na dispersão das estimativas de energia em relação ao cenário sem calibração, avaliando o impacto do *pile-up* sobre o desempenho dos modelos.

Tabela 16 – Ganho médio percentual do IQR para as configurações analisadas, em função de η , com a presença de *pile-up*

Configuração	Standard Rings	Quarter Rings
Com Extração de Atributos	13,77%	14,92%

Na Tabela 16, observa-se que os *Quarter Rings* obtiveram um ganho médio percentual de aproximadamente 14,92%, superior ao obtido pelos *Standard Rings*, que foi de aproximadamente 13,77%.




Figura 35 – Gráfico de resolução em função da energia na faixa de 40 a 50 GeV, considerando o efeito *pile-up*.

Tabela 17 – Ganho médio percentual do IQR para as configurações analisadas, em função da energia, com a presença de *pile-up*

Configuração	Standard Rings	Quarter Rings
Com Extração de Atributos	10,49%	10%

Essa diferença indica que, mesmo diante da complexidade adicional introduzida pelo *pile-up*, os *Quarter Rings* mantêm uma vantagem na capacidade de reduzir a dispersão das estimativas ao longo das faixas de pseudorapidez (η), reforçando sua eficácia em representar melhor os dados de entrada.

Por outro lado, a Tabela 17, que apresenta os resultados em função da energia após a extração de atributos, mostra uma diferença menos expressiva entre as duas configurações de aproximadamente: 10,49% para os *Standard Rings* e 10% para os *Quarter Rings*. Nesse caso, os *Standard Rings* tiveram desempenho ligeiramente superior.

De forma geral, a presença de *pile-up* torna os dados mais desafiadores, intensificando as variações nas métricas e ressaltando a importância de abordagens robustas de calibração. Ainda assim, os resultados obtidos confirmam que tanto os *Standard Rings* quanto os *Quarter Rings* são eficazes em reduzir a dispersão das estimativas, com os *Quarter Rings* demonstrando maior consistência especialmente nas análises em função de η .

5.1.5 Análise pelo Método da Extração de Variáveis Energéticas e Assimétricas com a Aplicação do Logaritmo na Soma das Energias do Calorímetro sem a Presença de *Pile-Up*

As Figuras 36 e 37, mostram uma abordagem alternativa em relação aos dados de entrada. Com o objetivo de reduzir a quantidade de características na entrada da árvore de decisão, os dados foram submetidos a um processo de extração de atributos, sendo que foi aplicado o logaritmo da soma das energias do calorímetro, pois a distribuição da energia depositada no detector exibe um perfil logarítmico [50].

Ressalta-se que este é um estudo em desenvolvimento. Os resultados obtidos com o algoritmo GBDT mostraram-se promissores, justificando sua apresentação nesta etapa do trabalho. Ajustes e aprimoramentos estão previstos como trabalhos futuros, com a expectativa de obter melhorias adicionais.

Após a calibração, podemos observar uma redução no espalhamento de α , o que indica melhoras significativas em relação aos dados não calibrados. O desempenho dos *Quarter Rings* foi superior ao dos *Standard Rings* todas as faixas de pseudorapidez e de energia.

Resultados Integrados em todas as faixas de energia




Figura 36 – Comportamento do IQR do fator α , em função de η . Os dados passaram por pela extração de variáveis energéticas e assimétricas com a aplicação do logaritmo na soma das energias do calorímetro, sem a presença de *pile-up*.

A Figura 38 apresenta o gráfico de resolução do modelo na faixa de energia entre 40 e 50 GeV. Embora os *Quarter Rings* tenham apresentado resultados superiores tanto da faixa de η quanto na faixa de energia, os *Standard Rings* demonstraram um desempenho ligeiramente melhor no gráfico de resolução, evidenciando menor dispersão nas estimativas, nesta faixa de energia.




Figura 37 – Comportamento do IQR do fator α , em função da energia. Os dados passaram por extração de atributos, sem a presença de *pile-up*.




Figura 38 – Gráfico de resolução em função da energia na faixa de 40 a 50 GeV. Os dados passaram por extração de atributos, sem a presença de *pile-up*.

As Tabelas 18 e 19 apresentam os ganhos médios percentuais do IQR obtidos após a aplicação das diferentes configurações de calibração, com extração de atributos com a aplicação do logarítmico da soma das energias do calorímetro, sem a presença de *pile-up*.

Tabela 18 – Ganho médio percentual do IQR para as configurações analisadas, em função de η , sem a presença de *pile-up*.

Configuração	Standard Rings	Quarter Rings
Com Extração de Atributos com o Log das Energias	6,39%	12,75%

Tabela 19 – Ganho médio percentual do IQR para as configurações analisadas, em função da energia, sem a presença de *pile-up*.

Configuração	Standard Rings	Quarter Rings
Com Extração de Atributos com o Log das Energias	8,96%	14,18%

Na Tabela 18, que mostra os ganhos em função da pseudorapidez (η), observa-se uma diferença significativa entre as duas configurações. Os *Quarter Rings* obtiveram um ganho médio percentual de aproximadamente 12,75%, enquanto os *Standard Rings* alcançaram apenas 6,39%. Esse resultado evidencia uma vantagem clara dos *Quarter Rings*, indicando que sua estrutura espacial mais refinada proporciona uma representação mais eficiente das informações ao longo das diferentes regiões de η .

A Tabela 19, que apresenta os resultados em função da energia, reforça essa tendência: os *Quarter Rings* obtiveram um ganho médio percentual de aproximadamente 14,18%, em comparação com 8,96% dos *Standard Rings*. A superioridade dos *Quarter Rings* nessa métrica indica que, além de melhorar o desempenho ao longo da pseudorapidez, essa configuração também é mais eficaz na redução da dispersão das estimativas em diferentes faixas de energia.

De modo geral, os resultados dessas tabelas confirmam a eficácia dos *Quarter Rings* na tarefa de calibração, especialmente quando combinados com extração de atributos. A melhoria mais expressiva nas métricas de IQR sugere que essa abordagem é mais adequada para capturar padrões relevantes nos dados.

5.1.6 Análise pelo Método da Extração de Variáveis Energéticas e Assimétricas com a Aplicação do Logaritmo na Soma das Energias do Calorímetro com a Presença de *Pile-Up*

As Figuras 39 e 40 apresentam a dispersão dos valores de IQR no qual foi aplicado um processo de extração de atributos que inclui a implementação do logaritmo na soma das energias do calorímetro eletromagnético. Essa estratégia tem como objetivo reduzir a dimensionalidade da entrada fornecida ao modelo de árvore de decisão, além de permitir a análise do impacto do *pile-up* no processo de calibração.

Após a aplicação da calibração, observa-se, em ambas as figuras, ocorreu uma redução no espalhamento dos valores do parâmetro α , indicando uma melhoria significativa em relação aos dados não calibrados. Além disso, verifica-se que os *Quarter Rings* apresentaram desempenho superior ao dos *Standard Rings* em todas as faixas de pseudorapidez e de energia. Esse resultado reforça a eficácia da configuração dos *Quarter Rings*, mesmo em um cenário mais desafiador como o que inclui *pile-up*, destacando sua robustez e potencial para melhorar a resolução das estimativas de energia.

Resultados Integrados em todas as faixas de energia




Figura 39 – Comportamento do IQR do fator α , em função de η . Os dados passaram por extração de atributos, com a presença de *pile-up*.

Na Figura 41 mostra o gráfico de resolução do modelo na faixa de energia de 40 a 50 GeV. Apesar dos *Quarter Rings* terem demonstrado resultados superiores em ambas as faixas, o gráfico de resolução apresenta um resultado similar com os *Standard Rings* nesta faixa de energia.




Figura 40 – Comportamento do IQR do fator α , em função da energia. Os dados passaram por extração de atributos, com a presença de *pile-up*.




Figura 41 – Gráfico de resolução em função da energia na faixa de 40 a 50 GeV, considerando o efeito *pile-up*.

Na Tabela 20, a qual mostra os resultados do ganho médio percentual em função da pseudorapidez (η), observa-se que os *Quarter Rings* tiveram um ganho médio de aproximadamente 12,58%, enquanto os *Standard Rings* obtiveram apenas 5,12%. Essa diferença expressiva evidencia que os *Quarter Rings* foram significativamente mais eficazes na redução da dispersão em diferentes regiões de η , mesmo diante da complexidade imposta pelo *pile-up*.

Tabela 20 – Ganho percentual do IQR para as configurações analisadas, em função de η , com a presença de *pile-up*

Configuração	Standard Rings	Quarter Rings
Com Extração de Atributos com o Log das Energias	5,12%	12,58%

Tabela 21 – Ganho percentual do IQR para as configurações analisadas, em função da energia, com a presença de *pile-up*

Configuração	Standard Rings	Quarter Rings
Com Extração de Atributos com o Log das Energias	6,63%	9,78%

De forma semelhante, a Tabela 21 apresenta os ganhos em função da energia. Novamente, os *Quarter Rings* superaram os *Standard Rings*, com ganhos médios de aproximadamente 9,78% e 6,63%, respectivamente. Apesar da diferença ser um pouco menor que no caso de η , ela ainda demonstra uma considerável vantagem dos *Quarter Rings*, sugerindo que essa configuração é mais robusta na presença de *pile-up*.

Em resumo, os resultados dessas tabelas confirmam que os *Quarter Rings* oferecem uma melhora mais expressiva nos valores das estimativas de energia. Mesmo em um cenário adverso com *pile-up*, essa abordagem se mostrou mais eficaz na redução da dispersão, destacando-se como uma alternativa promissora para aplicações que exigem maior precisão e estabilidade.

5.2 Resultados da Rede Neural *Feedforward*

Nesta seção, são apresentados os resultados da Rede Neural *Feedforward*, acompanhados pela análise dos gráficos do Intervalo Interquartil (IQR), utilizados para avaliar o desempenho dos métodos. A análise considera tanto os casos sem calibração quanto aqueles em que a calibração foi realizada por meio da Rede Neural. Além disso, as mesmas métricas de desempenho aplicadas à GBDT foram empregadas para avaliar a Rede Neural, permitindo uma comparação consistente entre os métodos.

Para avaliar a consistência e a capacidade de generalização do modelo de Rede Neural, foi aplicada a validação cruzada k-fold com k=5. Esse método permitiu dividir o conjunto de treinamento em cinco partições, garantindo que cada uma delas fosse utilizada alternadamente para validação e treinamento.

5.2.1 Análise pelo Método dos Dados Brutos sem a Presença de *Pile-Up*

A Figura 42 apresenta a variação do IQR da distribuição do fator de calibração α em função da pseudorapidez η . Os resultados abrangem a faixa de energia entre 10 GeV e 3.000 GeV e consideram dois conjuntos distintos de dados de entrada: *Standard Rings* e *Quarter Rings*. Ressalta-se que, neste cenário, não foi aplicada técnica alguma de extração de atributos e os dados analisados não contêm a presença de *pile-up*.




Figura 42 – Comportamento do IQR do fator α , em função de η , sem a presença de *pile-up*.

Após a aplicação da calibração, os resultados apresentados na Figura 42 indicam melhorias significativas em relação aos dados não calibrados. Observa-se uma redução no espalhamento dos valores de α , evidenciando o efeito positivo da calibração sobre os dados. Os *Quarter Rings* apresentaram desempenho superior aos *Standard Rings*, como detalhado na Tabela 22. No entanto, nas demais faixas de pseudorapidez (η), ambos os métodos mostraram desempenhos semelhantes.

Tabela 22 – Desempenho dos *Quarter Rings* em diferentes faixas de pseudorapidez

Faixa de η	Desempenho dos <i>Quarter Rings</i>
0,6 – 0,8	Superior
0,8 – 1,2	Superior
1,37 – 1,52	Superior
2,0 – 2,2	Superior
2,2 – 2,5	Superior
Demais faixas	Semelhante

A Figura 43, mostra o comportamento do IQR em função da energia. Observou-se que, os *Quarter Rings* apresentaram desempenho superior aos *Standard Rings* na maioria das faixas de energia, apresentadas na Tabela 23.




Figura 43 – Comportamento do IQR do fator α , em função da energia , sem a presença de *pile-up*.

Tabela 23 – Desempenho dos *Quarter Rings* em diferentes faixas de energia

Faixa de energia [GeV]	Desempenho dos <i>Quarter Rings</i>
5 – 10	Superior
10 – 20	Superior
30 – 40	Superior
40 – 50	Superior
50 – 70	Superior
100 – 150	Superior
150 – 200	Superior
200 – 250	Superior
900 – 3000	Superior
Demais faixas	Semelhante

A Figura 44 exibe o gráfico de resolução na faixa de energia de 40 a 50 GeV, escolhida para permitir a comparação com os resultados obtidos pelo GBDT. Observa-se que a calibração contribuiu para a redução da dispersão relativa das estimativas, tanto para os *Standard Rings* quanto para os *Quarter Rings*.




Figura 44 – Gráfico de resolução em função da energia na faixa de 40 a 50 GeV , sem a presença de *pile-up*.

As Tabelas 24 e 25 apresentam os ganhos percentuais do IQR obtidos após a aplicação da calibração por meio da rede neural, considerando os dados sem a presença de *pile-up* e sem aplicação de técnicas de extração de atributos. O objetivo dessa análise é quantificar o impacto da calibração na redução da dispersão das estimativas do fator α , tanto em função da pseudorapidez (η) quanto da energia.

Tabela 24 – Ganho percentual do IQR para as configurações analisadas, em função de η , sem a presença de *pile-up*.

Configuração	Standard Rings	Quarter Rings
Dados Brutos	18,02%	19,17%

Tabela 25 – Ganho percentual do IQR para as configurações analisadas, em função da energia, sem a presença de *pile-up*.

Configuração	Standard Rings	Quarter Rings
Dados Brutos	13,88%	14,62%

Na Tabela 24, observa-se que os *Quarter Rings* tiveram ganho médio de 19,17%, enquanto os *Standard Rings* teve o ganho médio de 18,02% ao longo das diferentes faixas de η . Esse resultado indica que, nesse cenário específico, as duas abordagens tiveram desempenho equivalente na tarefa de reduzir a variabilidade das estimativas com base na posição no calorímetro.

Já a Tabela 25, que mostra os resultados em função da energia, revela uma leve vantagem dos *Quarter Rings*, que obtiveram um ganho percentual de aproximadamente de 14,62%, em comparação com 13,88% dos *Standard Rings*. Embora a diferença seja pequena, ela sugere que os *Quarter Rings*

podem oferecer uma representação ligeiramente mais eficiente da calibração em função da energia, o que se reflete em uma melhora na qualidade das estimativas ao longo das faixas de energia.

De modo geral, os resultados indicam que a calibração com redes neurais é eficaz para reduzir a dispersão das estimativas, mesmo sem a extração de atributos. Além disso, os *Quarter Rings* demonstram um desempenho competitivo, especialmente em função da energia, o que reforça seu potencial como alternativa viável e robusta no processo de calibração.

5.2.2 Análise pelo Método dos Dados Brutos com a Presença de *Pile-Up*

As Figuras 45 e 46 permitem avaliar o impacto da presença de *pile-up* no processo de calibração. Assim como nas Figuras 42 e 43, os dados utilizados não passaram por extração de atributos.

Os resultados apresentados na Figura 45 mostram que os *Quarter Rings* apresentaram desempenho muito semelhante ao dos *Standard Rings* na maioria das faixas de pseudorapidez (η), conforme a Tabela 26, com exceção de duas faixas de (η).




Figura 45 – Comportamento do IQR do fator α , em função da η , com *pile-up* $\langle \mu \rangle$ na faixa de 25 a 52.

Tabela 26 – Desempenho dos *Quarter Rings* em diferentes faixas de pseudorapidez

Faixa de η	Desempenho dos <i>Quarter Rings</i>
0,6 – 0,8	Superior
Demais faixas	Semelhante

Na análise da Figura 46, observa-se com mais nitidez o impacto do *pile-up* sobre os dados em função da energia. Nota-se um aumento na dispersão das estimativas, indicando que o *pile-up* interferiu negativamente no desempenho da calibração. A Tabela 27 detalha o comportamento dos *Quarter Rings* nas diferentes faixas de energia, evidenciando uma perda de eficácia dos modelos frente ao aumento da complexidade introduzida pelo *pile-up*.

Tabela 27 – Desempenho dos *Quarter Rings* em diferentes faixas de energia

Faixa de energia [GeV]	Desempenho dos <i>Quarter Rings</i>
100 – 150	Superior
200 – 250	Superior
Demais faixas	Semelhante ou Pior

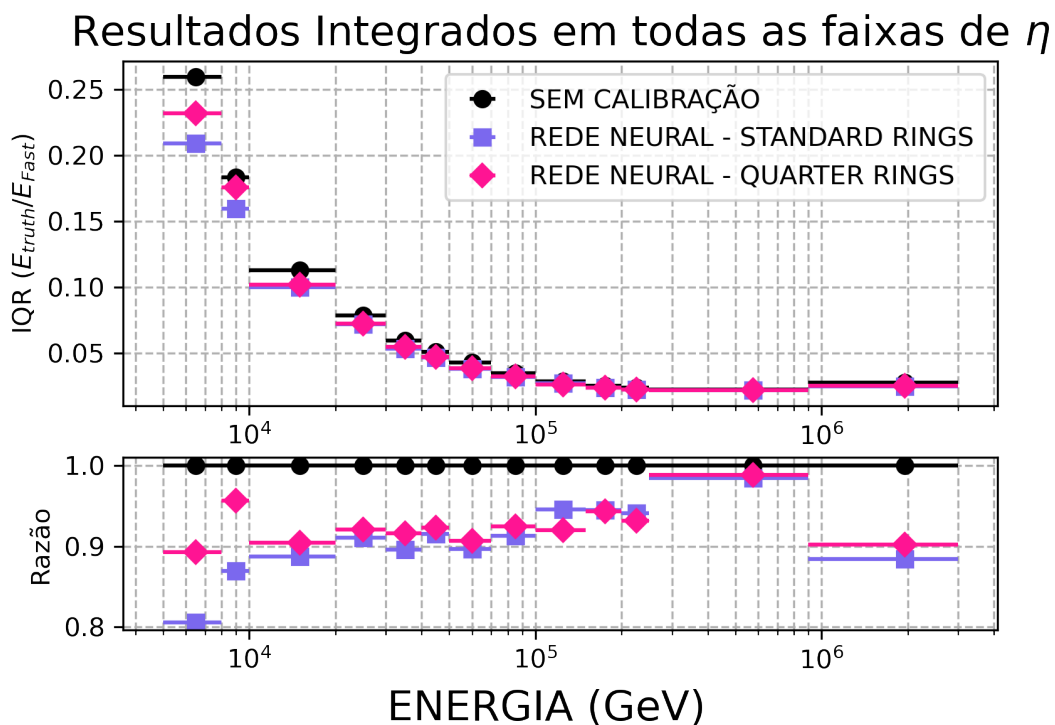


Figura 46 – Comportamento do IQR do fator α , em função da energia, com $pile-up < \mu >$ na faixa de 25 a 52.

A Figura 47 apresenta o gráfico de resolução para a faixa de energia entre 40 e 50 GeV. Observa-se que a calibração contribuiu para a redução da dispersão relativa dos valores estimados, o desempenho dos *Quarter Rings* foi similar aos dos *Standard Rings* nessa faixa de energia.




Figura 47 – Gráfico de resolução em função da energia na faixa de 40 a 50 GeV, considerando o efeito do $pile-up$.

As Tabelas 28 e 29 apresentam os ganhos percentuais do IQR após a aplicação da calibração utilizando redes neurais, considerando a presença de *pile-up*. Na Tabela 28, que avalia o desempenho em função de η , observa-se que os *Standard Rings* apresentaram um ganho médio percentual de aproximadamente 14,45%, enquanto os *Quarter Rings* alcançaram um ganho médio de aproximadamente 13,85%. Esses resultados indicam que, sob a influência do *pile-up*, os *Standard Rings* foram mais eficazes na redução da dispersão das estimativas ao longo das diferentes regiões do calorímetro.

Tabela 28 – Ganho percentual do IQR para as configurações analisadas, em função de η , com a presença de *pile-up*.

Configuração	Standard Rings	Quarter Rings
Dados Brutos	14,45%	13,85%

Tabela 29 – Ganho percentual do IQR para as configurações analisadas, em função da energia, com a presença de *pile-up*.

Configuração	Standard Rings	Quarter Rings
Dados Brutos	9,27%	7,47%

De forma semelhante, a Tabela 29 mostra os ganhos em função da energia. Novamente, os *Standard Rings* superaram os *Quarter Rings*, com ganhos médios de aproximadamente 9,27% e 7,47%, respectivamente. Embora a diferença não seja expressiva, ela sugere uma vantagem dos *Standard Rings* em cenários mais complexos, onde o *pile-up* tende a dificultar o processo de calibração.

De modo geral, os resultados indicam que, na presença de *pile-up* e sem a extração dos dados, os *Standard Rings* mantêm uma leve superioridade em relação aos *Quarter Rings*. Ainda assim, ambas as abordagens demonstram capacidade de melhorar significativamente a precisão das estimativas quando comparadas ao cenário sem calibração.

5.2.3 Análise pelo Método da Extração de Variáveis Energéticas e Assimétricas sem a Presença de *Pile-Up*

As Figuras 48 e 49 mostram uma abordagem alternativa em relação aos dados de entrada, com os dados submetidos a um processo de extração de atributos. A Figura 48 mostra que os dados calibrados obtiveram desempenho superior em relação aos dados não calibrados, evidenciando o efeito positivo da calibração na redução da dispersão das estimativas do fator α . Observa-se ainda que os *Quarter Rings* apresentaram desempenho superior ao dos *Standard Rings* em algumas faixas de pseudorapidez (η), com exceção de duas regiões específicas onde o desempenho foi similar, conforme detalhado na Tabela 30. Esses resultados reforçam a eficácia do processo de calibração e, ao mesmo tempo, demonstram que os *Quarter Rings* são competitivos em relação aos *Standard Rings*.

Resultados Integrados em todas as faixas de energia




Figura 48 – Comportamento do IQR do fator α , em função de η . Os dados passaram por extração de atributos, sem a presença de *pile-up*.

Tabela 30 – Desempenho dos *Quarter Rings* em diferentes faixas de pseudorapidez

Faixa de η	Desempenho dos <i>Quarter Rings</i>
0 – 0,6	Superior
1,37 – 1,52	Superior
1,52 – 1,8	Superior
1,8 – 2,0	Superior
2,2 – 2,5	Superior
Demais faixas	Semelhante

A Figura 49 evidencia uma melhora nos resultados obtidos com os *Quarter Rings* na maioria as faixas de energia, indicando um desempenho superior em relação aos *Standard Rings*. Essa tendência sugere que a configuração dos *Quarter Rings* foi mais eficaz na redução da dispersão das estimativas do fator α . A Tabela 31, destaca as faixas de energia em que os *Quarter Rings* apresentaram os melhores resultados, reforçando sua competitividade como alternativa na representação da calibração de energia.

Resultados Integrados em todas as faixas de η




Figura 49 – Comportamento do IQR do fator α , em função da energia. Os dados passaram por extração de atributos, sem a presença de *pile-up*.

Tabela 31 – Desempenho dos *Quarter Rings* em diferentes faixas de energia

Faixa de energia [GeV]	Desempenho dos <i>Quarter Rings</i>
30 – 40	Superior
40 – 50	Superior
70 – 100	Superior
100 – 150	Superior
150 – 200	Superior
200 – 250	Superior
Demais faixas	Semelhante

A Figura 50 apresenta o gráfico de resolução do modelo na faixa de energia entre 40 e 50 GeV. No gráfico em função da energia, os *Quarter Rings* apresentaram um bom desempenho ao reduzir as dispersões quando comparado com os dados sem calibração, tornando as estimativas mais estáveis e confiáveis.

As Tabelas 32 e 33 apresentam os ganhos médios percentuais no IQR obtidos após a calibração com redes neurais, com a aplicação de extração de atributos e com ausência de *pile-up*. Na Tabela 32, observa-se que os *Quarter Rings* apresentaram um ganho médio percentual de aproximadamente 19,05% superior ao obtido pelos *Standard Rings*, que alcançaram aproximadamente 17,86%. Essa diferença, embora pequena, evidencia a competitividade dos *Quarter Rings* e sua capacidade de capturar adequadamente a variação espacial da resposta do calorímetro ao longo de η .

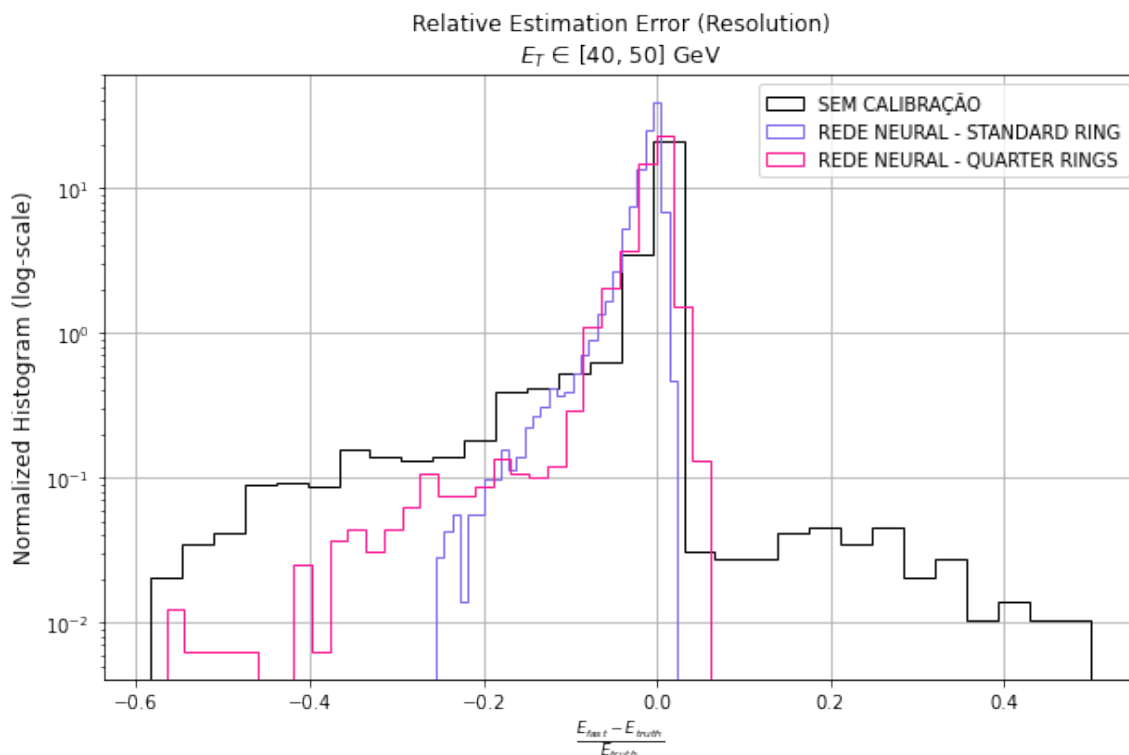


Figura 50 – Gráfico de resolução em função da energia na faixa de 20 a 30 GeV. Os dados passaram por extração de atributos, sem a presença de *pile-up*.

Tabela 32 – Ganho médio percentual do IQR para as configurações analisadas, em função de η , sem a presença de *pile-up*.

Configuração	Standard Rings	Quarter Rings
Com Extração de Atributos	17,86%	19,05%

Tabela 33 – Ganho médio percentual do IQR para as configurações analisadas, em função da energia, sem a presença de *pile-up*.

Configuração	Standard Rings	Quarter Rings
Com Extração de Atributos	14,08%	14,33%

Por outro lado, na Tabela 33, que apresenta os resultados em função da energia, ambos os métodos obtiveram desempenhos praticamente equivalentes: os *Standard Rings* alcançaram um ganho médio de aproximadamente 14,08%, enquanto os *Quarter Rings* obtiveram um ganho médio de aproximadamente 14,33%. Essa proximidade nos valores indica que, nesse cenário, ambas as representações dos dados de entrada foram igualmente eficazes na redução da dispersão das estimativas de energia.

De forma geral, os resultados reforçam a eficácia da calibração por rede neural na melhoria da qualidade das estimativas, especialmente quando os dados passam por um processo de extração de atributos. Além disso, os *Quarter Rings* se mostram uma alternativa tão eficiente quanto os *Standard Rings*, apresentando uma leve vantagem nas análises em função da pseudorapidez.

5.2.4 Análise pelo Método da Extração de Variáveis Energéticas e Assimétricas com a Presença de *Pile-Up*

As Figuras 51 e 52 permitem avaliar o impacto do *pile-up* no processo de calibração, considerando a aplicação da extração de atributos, assim como nas Figuras 48 e 49. Os resultados mostram que os *Quarter Rings* apresentaram desempenho superior aos *Standard Rings* na maioria das faixas de pseudorapidez (η), conforme detalhado na Tabela 34. Esse comportamento indica que, embora o *pile-up* afete o desempenho da calibração, o modelo ainda mantém certo grau de robustez, com os *Quarter Rings* demonstrando competitividade mesmo sob condições mais desafiadoras.




Figura 51 – Comportamento do IQR do fator α , em função de η . Os dados passaram por extração de atributos, com a presença de *pile-up*.

Tabela 34 – Desempenho dos *Quarter Rings* em diferentes faixas de pseudorapidez

Faixa de η	Desempenho dos <i>Quarter Rings</i>
0,6 – 0,8	Superior
0,8 – 1,2	Superior
1,2 – 1,37	Superior
1,52 – 1,8	Superior
Demais faixas	Semelhante

A análise da Figura 52 evidencia com mais clareza o impacto do *pile-up* sobre os dados em função da energia. Observa-se uma degradação na qualidade das estimativas em determinadas faixas, indicando que o *pile-up* afetou o desempenho da calibração. A Tabela 35 detalha o comportamento dos *Quarter Rings* ao longo das diferentes faixas de energia.




Figura 52 – Comportamento do IQR do fator α , em função da energia. Os dados passaram por extração de atributos, com a presença de *pile-up*.

Tabela 35 – Desempenho dos *Quarter Rings* em diferentes faixas de energia

Faixa de energia [GeV]	Desempenho dos <i>Quarter Rings</i>
50 – 70	Superior
70 – 100	Superior
100 – 150	Superior
150 – 200	Superior
250 – 900	Pior
Demais faixas	Semelhante

A Figura 53 apresenta o gráfico de resolução para a faixa de energia entre 40 e 50 GeV. Observa-se que a calibração contribuiu para a redução da dispersão relativa dos valores estimados, o desempenho dos *Standard Rings* foi melhor do que os dos *Quarter Rings* nessa faixa de energia.

As Tabelas 36 e 37 apresentam os ganhos médio percentuais do IQR obtidos após a aplicação das estratégias de calibração utilizando as configurações *Standard Rings* e *Quarter Rings*, considerando a presença de *pile-up*.

Tabela 36 – Ganho médio percentual do IQR para as configurações analisadas, em função de η , com a presença de *pile-up*.

Configuração	Standard Ring	Quarter Rings
Com Extração de Atributos	13,78%	14,55%

Tabela 37 – Ganho médio percentual do IQR para as configurações analisadas, em função da energia, com a presença de *pile-up*.

Configuração	Standard Rings	Quarter Rings
Com Extração de Atributos	9,35%	8,18%

Em relação à pseudorapidez (η), observada na Tabela 36, os *Quarter Rings* apresentaram um




Figura 53 – Gráfico de resolução em função da energia na faixa de 40 a 50 GeV, considerando o efeito *pile-up*.

desempenho superior, com um ganho médio de aproximadamente 13,78%, em comparação aos 14,55% obtidos com os *Standard Rings*. Essa diferença, embora modesta, sugere que os *Quarter Rings* mantêm sua capacidade de captar variações mesmo em cenários com maior complexidade, como é o caso da presença de *pile-up*.

Por outro lado, na análise em função da energia, Tabela 37, os resultados foram mais favoráveis aos *Standard Rings*, que obtiveram um ganho médio de aproximadamente 9,35%, frente aos 8,18% dos *Quarter Rings*. Isso indica que, sob essas condições, os *Standard Rings* mostraram-se mais eficazes na redução da dispersão das estimativas ao longo da faixa de energia.

Esses resultados reforçam que o desempenho relativo entre as duas configurações pode variar de acordo com a variável de análise e com a complexidade dos dados. Enquanto os *Quarter Rings* apresentam vantagens em termos de pseudorapidez, os *Standard Rings* se destacam ligeiramente na calibração em função da energia quando há *pile-up* envolvido.

Tanto o GBDT quanto a rede neural demonstraram ser capazes de lidar com a complexidade dos dados experimentais, capturando relações não-lineares e ajustando modelos que minimizam os erros de medição. Isso resulta em uma calibração mais precisa e confiável dos dados do calorímetro.

5.3 Comparação das Abordagens de Calibração

A análise comparativa entre os modelos de aprendizado de máquina baseados em GBDT e redes neurais do tipo MLP foi conduzida considerando diferentes condições experimentais, com o objetivo de avaliar o desempenho na estimativa da energia de partículas. Os cenários avaliados incluem a presença ou ausência de *pile-up*, bem como o impacto da aplicação de diferentes estratégias de extração de variáveis energéticas e assimétricas.

Para ambas as técnicas, foram testadas duas configurações distintas de entrada: (i) com a utilização somente dos dados brutos; (ii) com a extração de variáveis energéticas e assimétricas, baseada em estatísticas e características geométricas dos calorímetros.

5.3.1 Comparação entre os Resultados da GBDT com e sem *Pile-Up*, com a Utilização do Método dos Dados Brutos

A comparação direta entre os resultados obtidos com e sem *pile-up*, utilizando o GBDT com o método dos dados brutos, permite avaliar o impacto do *pile-up* na qualidade das estimativas. Nesta seção, essa comparação foi realizada por meio da análise dos gráficos de IQR, focando nas regiões em que os *Quarter Rings* apresentaram o melhor desempenho.

A Tabela 38 apresenta os resultados por faixa de pseudorapidez, enquanto a Tabela 39 mostra a comparação em função da energia, apenas para os dados sem *pile-up*, já que, com a presença do *pile-up*, os métodos mantiveram desempenhos competitivos entre si.

Tabela 38 – Comparação do desempenho dos *Quarter Rings* em diferentes faixas de pseudorapidez, com e sem *pile-up*

Faixa de η	Sem <i>pile-up</i>	Com <i>pile-up</i>
0,6 – 0,8	Superior	Superior
1,37 – 1,52	—	Superior
1,52 – 1,8	Superior	Superior
1,8 – 2,0	Superior	—
2,2 – 2,5	Superior	—
Demais faixas	Semelhante	Semelhante

Tabela 39 – Desempenho dos *Quarter Rings* em diferentes faixas de energia

Faixa de energia [GeV]	Desempenho dos <i>Quarter Rings</i>
50 – 70	superior
70 – 100	superior
100 – 150	superior
150 – 200	superior
Demais faixas	Semelhante

Esses resultados indicam que o *pile-up* compromete de forma limitada o desempenho da calibração, dificultando a redução da dispersão das estimativas — um efeito esperado, dada a maior complexidade e o ruído introduzido por interações adicionais no evento. No entanto, os ganhos obtidos com a calibração permanecem expressivos, o que evidencia a eficácia do modelo GBDT em lidar com variações nos dados.

Mesmo em cenários adversos, a abordagem baseada em aprendizado de máquina demonstrou ser robusta, promovendo melhorias significativas na qualidade das estimativas.

Em resumo, a calibração permanece eficiente na redução da dispersão das estimativas, demonstrando-se robusta a dispersão dos dados mesmo em cenários mais desafiadores, como aqueles em que ocorrem eventos simultâneos no detector. Os métodos apresentados neste trabalho reforçam a confiabilidade do GBDT como ferramenta de calibração em ambientes com complexidade aumentada.

5.3.2 Comparação entre os Resultados da GBDT com e sem *Pile-Up*, pelo Método da Extração de Variáveis Energéticas e Assimétricas

A Tabela 40 apresenta a comparação das regiões em relação a pseudorapidez onde os *Quarter Rings* tiveram o melhor resultado, sem e com a presença do *pile-up*. Na Tabela 41 mostra a região em relação a energia onde os *Quarter Rings* teve melhor desempenho para os dados sem a presença de *pile-up*, pois com efeito do *pile-up* as abordagens utilizadas na calibração tiveram desempenho similar.

Tabela 40 – Comparação do desempenho dos *Quarter Rings* em diferentes faixas de pseudorapidez, com e sem *pile-up*

Faixa de η	Sem <i>pile-up</i>	Com <i>pile-up</i>
0 – 0,6	Superior	Superior
0,6 – 0,8	—	Superior
0,8 – 1,2	—	Superior
1,52 – 1,8	Superior	Superior
1,8 – 2,0	Superior	Superior
2,0 – 2,2	—	Superior
2,2 – 2,5	Superior	Superior
Demais faixas	Semelhante	Semelhante

Tabela 41 – Desempenho dos *Quarter Rings* em diferentes faixas de energia

Faixa de energia [GeV]	Desempenho dos <i>Quarter Rings</i>
70 – 100	Superior
100 – 150	Superior
150 – 200	Superior
Demais faixas	Semelhante

A redução da dimensionalidade por meio da extração de atributos contribuiu para a eficácia da calibração com GBDT, que se manteve eficiente na diminuição da dispersão das estimativas de energia. Ao comparar os resultados com e sem a presença de *pile-up*, observa-se um desempenho superior nos dados livres dessa interferência. Embora os métodos de calibração apresentem boa robustez a dispersão dos dados de forma geral, o *pile-up* impacta de maneira mais significativa a dispersão das estimativas de energia nos *Quarter Rings*, enquanto seus efeitos nas diferentes faixas de pseudorapidez são menos pronunciados.

5.3.3 Comparação entre os Resultados da GBDT com e sem *Pile-Up*, com a aplicação do logarítmico na soma das energias do calorímetro

Na análise da calibração em função da pseudorapidez (η) e da energia, observa-se que os *Quarter Rings* apresentam maior estabilidade em todas as faixas do calorímetro, mesmo diante das perturbações introduzidas pelo *pile-up*. Esse comportamento reforça a robustez da técnica, especialmente em cenários com maior complexidade experimental.

5.3.4 Comparação entre os Resultados da Rede Neural com e sem *Pile-Up*, com o Método dos Dados Brutos

Esta seção apresenta uma análise comparativa do desempenho da calibração realizada por redes neurais utilizando dados brutos, ou seja, sem aplicação de técnicas de extração de variáveis energéticas e assimétricas, nos cenários sem e com a presença de *pile-up*. O objetivo é avaliar o impacto do *pile-up* na capacidade do modelo em reduzir a dispersão das estimativas do fator de calibração α .

Os gráficos de IQR em função da pseudorapidez (η) e da energia permitem avaliar o impacto da presença do *pile-up* no desempenho da calibração realizada pela rede neural. Podemos ver pelo comparativo das Tabelas 42 e 43 que os resultados sem a presença de *pile-up* teve melhor resultado em relação aos dados com *pile-up*, tanto em relação a η quanto em relação a energia.

Tabela 42 – Comparação do desempenho dos *Quarter Rings* em diferentes faixas de pseudorapidez, sem e com *pile-up*

Faixa de η	Sem <i>pile-up</i>	Com <i>pile-up</i>
0,6 – 0,8	Superior	Superior
0,8 – 1,2	Superior	-
1,37 – 1,52	Superior	-
2,0 – 2,2	Superior	-
2,2 – 2,5	Superior	-
Demais faixas	Semelhante	Semelhante

Tabela 43 – Comparação do desempenho dos *Quarter Rings* em diferentes faixas de energia, sem e com *pile-up*

Faixa de energia [GeV]	Sem <i>pile-up</i>	Com <i>pile-up</i>
5 – 10	Superior	-
10 – 20	Superior	-
30 – 40	Superior	-
40 – 50	Superior	-
50 – 70	Superior	-
100 – 150	Superior	Superior
150 – 200	Superior	-
200 – 250	Superior	Superior
900 – 3000	Superior	-
Demais faixas	Semelhante	Semelhante ou Pior

De modo geral, os resultados indicam que, mesmo com a presença de *pile-up*, o método baseado em dados brutos com a abordagem dos *Quarter Rings* apresentou desempenho competitivo em relação à

abordagem tradicional dos *Standard Rings*. A calibração por meio de redes neurais demonstrou-se eficaz na mitigação das interferências introduzidas por um ambiente experimental mais complexo.

5.3.5 Comparação entre os Resultados da Rede Neural com e sem *Pile-Up*, Com o Método da Extração de Variáveis Energéticas e Assimétricas

A comparação entre os cenários com e sem *pile-up*, utilizando dados que passaram pelo método da extração de variáveis energéticas e assimétricas, permite avaliar o impacto direto desse método na eficácia da calibração por meio da rede neural. As análises levam em consideração o desempenho dos *Quarter Rings* tanto em relação a pseudorapidez (η) quanto em relação a energia das partículas, conforme pode ser visto nas Tabelas 44 e 45.

Tabela 44 – Comparação do desempenho dos *Quarter Rings* com redes neurais em diferentes faixas de pseudorapidez, com e sem *pile-up*

Faixa de η	Sem <i>pile-up</i>	Com <i>pile-up</i>
0 – 0,6	Superior	-
0,6 – 0,8	-	Superior
0,8 – 1,2	-	Superior
1,2 – 1,37	-	Superior
1,37 – 1,52	Superior	-
1,52 – 1,8	Superior	Superior
1,8 – 2,0	Superior	-
2,2 – 2,5	Superior	-
Demais faixas	Semelhante	Semelhante

Tabela 45 – Comparação do desempenho dos *Quarter Rings* em diferentes faixas de energia, sem e com *pile-up*

Faixa de energia [GeV]	Sem <i>pile-up</i>	Com <i>pile-up</i>
30 – 40	Superior	-
40 – 50	Superior	-
50 – 70	-	Superior
70 – 100	Superior	Superior
100 – 150	Superior	Superior
150 – 200	Superior	Superior
200 – 250	Superior	-
250 – 900	-	Pior
Demais faixas	Semelhante	Semelhante

Os resultados obtidos sem a presença de *pile-up* apresentaram desempenho superior em comparação àqueles com *pile-up*, como era esperado. Ainda assim, mesmo sob essas perturbações, os resultados permaneceram consistentes, evidenciando que, mesmo em cenários mais desafiadores, o processo de calibração foi eficaz. Nesse contexto, os *Quarter Rings* demonstraram-se uma abordagem vantajosa para a calibração.

De forma geral, a eficácia da calibração associada à extração de atributos contribuiu para mitigar esses efeitos. Os *Quarter Rings* apresentaram melhor desempenho nas faixas de pseudorapidez, enquanto os *Standard Rings* mostraram-se mais estáveis ao longo das diferentes faixas de energia.

5.4 Comparativo de Resultados entre GBDT e a Rede Neural

Com o objetivo de comparar as abordagens de aprendizado de máquina, será avaliado qual método apresentou melhor desempenho no processo de calibração. A análise será restrita aos dados sem *pile-up*, uma vez que os efeitos decorrentes de múltiplas interações simultâneas não demonstraram impacto adverso significativo que comprometa os resultados. Também serão considerados os dados correspondentes aos *Quarter Rings*, por se tratar de uma abordagem capaz de capturar as assimetrias do detector, além de apresentar, em diferentes situações, desempenho superior ou comparável ao *Standard Ring*, conforme já discutido neste trabalho. Essa escolha contribui ainda para evitar redundâncias textuais, mantendo o foco na comparação entre as diferentes estratégias de calibração.

5.4.1 Análise pelo Método dos Dados Brutos sem a Presença de *Pile-Up*

Na Figura 54, é apresentada a comparação da calibração da estrutura assimétrica *Quarter Rings* utilizando os métodos de aprendizado de máquina GBDT e rede neural. Observa-se, no gráfico em função de η , que ambos os métodos apresentaram desempenhos equivalentes de forma geral, com variações ao longo das diferentes faixas de pseudorapidez, apresentados na Tabela 46. Em determinadas regiões, o GBDT apresentou resultados superiores, enquanto em outras a rede neural se destacou, especialmente nas faixas associadas a maiores energias, onde seu desempenho foi superior.




Figura 54 – Comportamento do IQR do fator α , em função da η , sem a presença de *pile-up*.

Na Figura 55, apresenta-se o desempenho dos modelos em função da energia. A Tabela 47 indica as faixas de energia nas quais cada modelo obteve seu melhor desempenho. Observa-se que, embora ambos os modelos tenham mantido resultados próximos, o método GBDT apresentou desempenho superior em um maior número nas faixas de energia em comparação à rede neural.

Tabela 46 – Comparação de desempenho entre GBDT e Rede Neural em diferentes faixas de pseudorapidez

Faixa de η	Desempenho dos <i>Quarter Rings</i>
0 – 0,6	GBDT
0,6 – 0,8	GBDT
0,8 – 1,2	Rede Neural
1,2 – 1,37	Rede Neural
1,37 – 1,52	GBDT
1,52 – 1,8	GBDT
1,8 – 2,0	Rede Neural
2,0 – 2,2	Rede Neural
2,2 – 2,5	Rede Neural

Resultados Integrados em todas as faixas de η

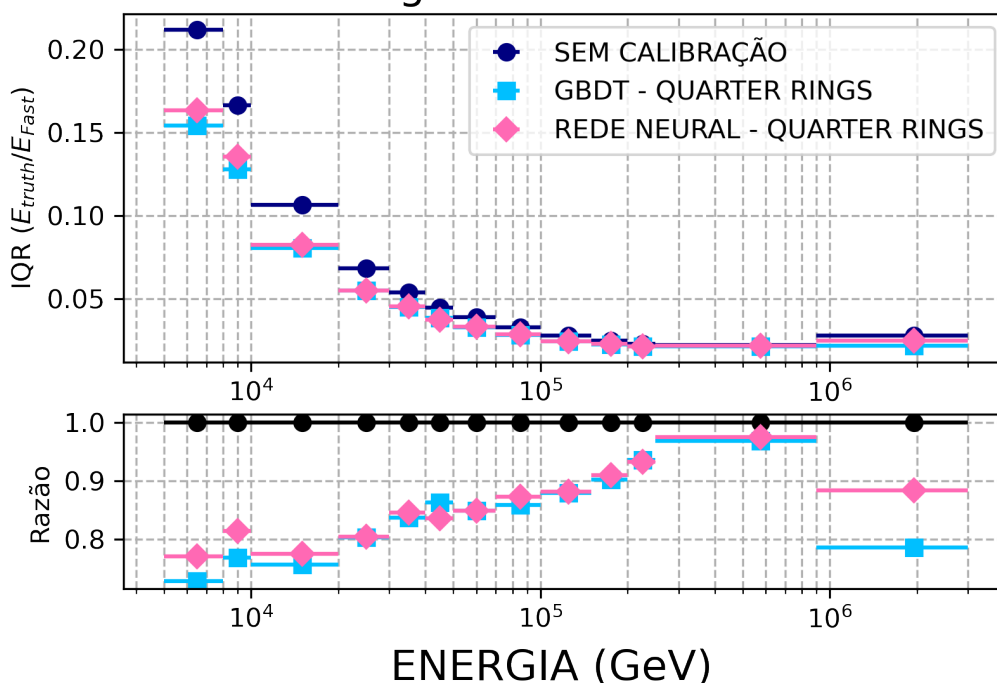


Figura 55 – Comportamento do IQR do fator α , em função da η , sem a presença de *pile-up*.

Tabela 47 – Comparação de desempenho entre GBDT e Rede Neural em diferentes faixas de energia

Faixa de η	Desempenho dos <i>Quarter Rings</i>
0 – 5	GBDT
5 – 10	GBDT
10 – 20	GBDT
30 – 40	GBDT
40 – 50	Rede Neural
70 – 100	GBDT
150 – 200	GBDT
200 – 250	Rede Neural
250 – 900	GBDT
900 – 3000	GBDT
Demais faixas	Semelhante

Em resumo, a análise do desempenho em função da pseudorapidez e da energia demonstra que tanto o método GBDT quanto a rede neural apresentam resultados competitivos, com vantagens específicas em diferentes faixas. O GBDT destacou-se em um maior número de faixas de energia e manteve desempenho competitivo ao longo das regiões de η , enquanto a rede neural obteve melhor desempenho especialmente nas maiores faixas de energia em relação a pseudorapidez.

5.4.2 Análise pelo Método da Extração de Variáveis Energéticas e Assimétricas sem a Presença de *Pile-Up*

Observa-se na Figura 56, em função de η , que a rede neural apresentou melhor desempenho em quase todas as faixas de pseudorapidez, conforme evidenciado na Tabela 48.




Figura 56 – Comportamento do IQR do fator α , em função da η , sem a presença de *pile-up*.

Tabela 48 – Comparação de desempenho entre GBDT e Rede Neural em diferentes faixas de pseudorapidez

Faixa de η	Desempenho dos <i>Quarter Rings</i>
0 – 0,6	Rede Neural
0,6 – 0,8	Rede Neural
0,8 – 1,2	GBDT
1,2 – 1,37	Rede Neural
1,37 – 1,52	Rede Neural
1,52 – 1,8	Semelhante
1,8 – 2,0	Rede Neural
2,0 – 2,2	Rede Neural
2,2 – 2,5	Rede Neural

A Figura 57 exibe o desempenho dos modelos em função da energia, enquanto a Tabela 49 apresenta as faixas de energia em que cada modelo alcançou seu melhor resultado. Apesar de ambos os

métodos apresentarem desempenhos semelhantes, o GBDT sobressaiu-se na maioria das faixas de energia, superando a rede neural.

Resultados Integrados em todas as faixas de η

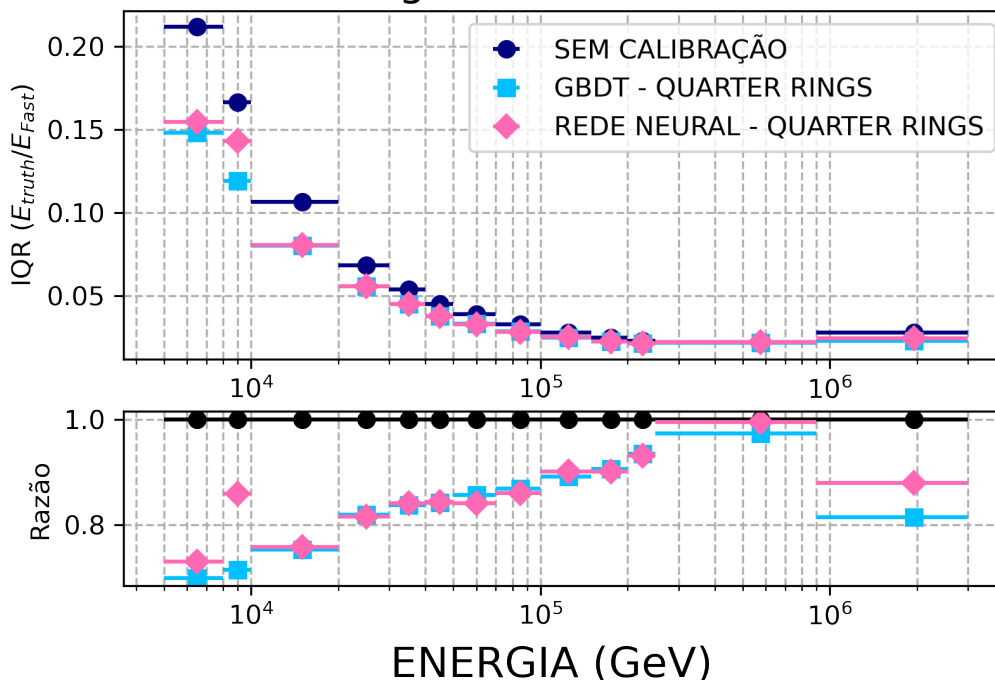


Figura 57 – Comportamento do IQR do fator α , em função da η , sem a presença de *pile-up*.

As Figuras 56 e 57 apresentam o desempenho dos modelos GBDT e rede neural em função da pseudorapidez (η) e da energia, respectivamente. Conforme indicado nas Tabelas 48 e 49, a rede neural mostrou desempenho superior na maioria das faixas de pseudorapidez, enquanto o GBDT destacou-se em mais faixas de energia. Em faixas específicas, ambos os métodos apresentaram resultados semelhantes, evidenciando uma complementaridade entre as abordagens.

Tabela 49 – Comparação de desempenho entre GBDT e Rede Neural em diferentes faixas de energia

Faixa de η	Desempenho dos <i>Quarter Rings</i>
0 – 5	GBDT
5 – 10	GBDT
10 – 20	GBDT
20 – 30	Rede Neural
30 – 40	GBDT
40 – 50	Semelhante
50 – 70	Rede Neural
70 – 100	Rede Neural
100 – 150	GBDT
150 – 200	Rede Neural
200 – 250	Rede Neural
250 – 900	GBDT
900 – 3000	GBDT

Tanto o GBDT quanto a rede neural apresentaram bons desempenhos no processo de calibração, tanto com os dados brutos quanto com os dados submetidos à extração de atributos. No entanto, cada abordagem possui particularidades que influenciam seu desempenho em diferentes cenários. Independentemente da estratégia adotada, os resultados mostram que cada método se destaca em faixas específicas. Nos dados brutos, por exemplo, o GBDT teve melhor desempenho nas faixas de pseudorapidez (η), enquanto, com a extração de atributos, a rede neural foi superior nessa mesma região. Uma tendência semelhante é observada nas faixas de energia.

Dessa forma, a escolha do modelo mais adequado dependerá dos recursos disponíveis, do tempo necessário para a calibração e da região do detector em que se deseja obter maior acurácia. Em termos gerais, ambos os métodos apresentaram vantagens na tarefa de calibração como pode ser visto nas Tabelas 50 e 51, cada um com melhor desempenho em diferentes regiões do detector.

Tabela 50 – Comparação do desempenho entre GBDT e Rede Neural nas diferentes faixas de pseudorapidez para os dois métodos de análise

Faixa de η	Método Dados Brutos	Método da Extração de Variáveis Energéticas e Assimétricas
0 – 0,6	GBDT	Rede Neural
0,6 – 0,8	GBDT	Rede Neural
0,8 – 1,2	Rede Neural	GBDT
1,2 – 1,37	Rede Neural	Rede Neural
1,37 – 1,52	GBDT	Rede Neural
1,52 – 1,8	GBDT	Semelhante
1,8 – 2,0	Rede Neural	Rede Neural
2,0 – 2,2	Rede Neural	Rede Neural
2,2 – 2,5	Rede Neural	Rede Neural

Tabela 51 – Comparação do desempenho entre GBDT e Rede Neural nas diferentes faixas de energia para os dois métodos de análise

Faixa de energia [GeV]	Método Dados Brutos	Método da Extração de Variáveis Energéticas e Assimétricas
0 – 5	GBDT	GBDT
5 – 10	GBDT	GBDT
10 – 20	GBDT	GBDT
20 – 30	Semelhante	Rede Neural
30 – 40	GBDT	GBDT
40 – 50	Rede Neural	Semelhante
50 – 70	Semelhante	Rede Neural
70 – 100	GBDT	Rede Neural
100 – 150	Semelhante	GBDT
150 – 200	GBDT	Rede Neural
200 – 250	Rede Neural	Rede Neural
250 – 900	GBDT	GBDT
900 – 3000	GBDT	GBDT

6 Considerações Finais

Este estudo avaliou diferentes estratégias de calibração para estimar o fator α , considerando variações na estrutura dos dados de entrada, desde dados brutos até abordagens com extração de atributos, em cenários com e sem a presença de *pile-up*.

Os resultados demonstraram que os métodos supervisionados de calibração de energia foram eficazes na redução consistente da dispersão das estimativas, mesmo sob as condições adversas impostas pelo *pile-up*. Embora o impacto do *pile-up* na eficácia das abordagens de calibração — independentemente da estratégia de entrada utilizada — já fosse esperado, sua interferência variou conforme o modelo adotado, o tipo de extração de atributos e a variável considerada (pseudorapidez ou energia). A análise dos valores de IQR em função da pseudorapidez (η) e da energia, juntamente com os gráficos de resolução, evidenciou ganhos significativos, confirmando a capacidade dos modelos calibrados de capturar variações complexas na resposta do detector.

Essas variações manifestaram-se de maneira distinta ao longo do calorímetro e conforme o modelo de aprendizado utilizado. Observou-se que os *Quarter Rings* superaram os *Standard Rings* em determinadas regiões, enquanto em outras o desempenho foi semelhante. De modo análogo, tanto o GBDT quanto a rede neural apresentaram ganhos específicos, variando conforme as faixas de η e energia a depender do método de aprendizado aplicado. Embora a presença de *pile-up* tenha reduzido um pouco os ganhos médios, nenhuma configuração foi significativamente mais afetada que a outra. Os *Quarter Rings*, em particular, demonstraram maior estabilidade nas regiões mais críticas do detector.

A segmentação mais refinada proporcionada pelos *Quarter Rings* permitiu capturar assimetrias do chuveiro eletromagnético nas direções η e ϕ , contribuindo para melhorias na resolução da energia estimada. Embora os desempenhos sejam próximos aos dos *Standard Rings* em algumas regiões, os *Quarter Rings* mostraram vantagens pontuais mais evidentes quando combinados com a extração de atributos.

A calibração supervisionada, aliada tanto ao GBDT quanto à rede neural, revelou-se uma abordagem robusta e eficaz. Ambas as técnicas mantiveram bom desempenho frente às variações nas condições dos dados, sendo que os *Quarter Rings* se destacaram por sua capacidade de reduzir as dispersões. Assim, a metodologia proposta constitui uma alternativa promissora para aprimorar a precisão e confiabilidade da calibração no detector ATLAS.

A utilização da técnica de extração de atributos revelou diferenças sutis, porém relevantes, entre os cenários com e sem a presença de *pile-up*, ao permitir a redução da dimensionalidade dos dados sem comprometer a eficácia da calibração. Tanto os *Standard Rings* quanto os *Quarter Rings* mantiveram bom desempenho na redução da dispersão; contudo, em faixas específicas de energia e pseudorapidez, os *Quarter Rings* continuaram a se destacar, evidenciando vantagens estruturais em relação à configuração padrão.

A aplicação da técnica de extração de atributos permitiu reduzir a dimensionalidade dos dados sem comprometer a eficácia da calibração, revelando diferenças sutis, porém significativas, entre os cenários com e sem *pile-up*. Tanto os *Standard Rings* quanto os *Quarter Rings* apresentaram bom desempenho na

redução da dispersão, mas os *Quarter Rings* continuaram a se destacar tanto na energia quanto para a pseudorapidez, evidenciando vantagens estruturais em relação à configuração padrão.

Com a implementação do GBDT, observou-se, no cenário dos dados brutos sem o efeito do *pile-up*, os ganhos médios no IQR em função de η de 14,91% para os *Standard Rings* e 15,82% para os *Quarter Rings*; em função da energia, os ganhos foram de 13,47% e 13,79%, respectivamente. Com o método da extração de variáveis energéticas e assimétricas sem o efeito do *pile-up*, os ganhos em η foram de 15,38% e 15,33%, e em energia, de 15,3% e 14,95%, respectivamente.

Os efeitos do *pile-up* nos resultados do método dos dados brutos acarretaram uma leve intervenção: para os *Standard Rings* os ganhos médios obtidos pela GBDT foram de 13,44% e para os *Quarter Rings* foram de 13,49% em relação a η . Em relação a energia os ganhos médios para os *Standard Rings* e *Quarter Rings* foram de 11,49% e 11,18% respectivamente. Com o método da extração de variáveis energéticas e assimétricas, os ganhos em η aumentaram para 13,77% e 14,92%, e, em energia, para 10,49% e 10,00%, respectivamente.

A aplicação da rede neural resultou em um desempenho ainda mais expressivo. Pelo método dos dados brutos, os ganhos médios em η foram de 18,02% para os *Standard Rings* e de 19,17% para os *Quarter Rings*, e em energia, de 13,88% para os *Standard Rings* e 14,62% para os *Quarter Rings*. Com o método da extração de variáveis energéticas e assimétricas, os ganhos em η foram de 17,89% para os *Standard Rings* e 19,05% para os *Quarter Rings*, e em energia, de 14,08% e 14,33%, respectivamente.

A influência do efeito do *pile-up* para a rede neural foi de 14,45% para os *Standard Rings* e de 13,85% para os *Quarter Rings* em relação a η . Em relação a energia, os ganhos médios foram de 9,27% para os *Standard Rings* e de 7,47% para os *Quarter Rings*. Em relação ao método da extração de variáveis energéticas e assimétricas os ganhos médios obtidos foram de 13,78% para os *Standard Rings* e de 14,55% para os *Quarter Rings* em relação a η . E em relação a energia foram de 9,35% para os *Standard Rings* e de 8,18% para os *Quarter Rings*.

Esses resultados evidenciam a eficácia dos *Quarter Rings*, que se mostraram superiores quando comparados aos dados sem calibração e, em diversos cenários, apresentaram desempenho semelhante ou superior ao dos *Standard Rings*. A combinação de estruturas espacialmente refinadas com técnicas de aprendizado de máquina mostrou-se promissora para aprimorar a calibração do calorímetro do ATLAS, mesmo em condições adversas como a presença de *pile-up*.

De modo geral, os resultados reforçam o potencial dos métodos de aprendizado de máquina, especialmente quando aliados a representações espaciais mais segmentadas, para uma calibração de energia mais precisa no ATLAS. Como trabalho futuro, propõe-se explorar a incorporação de conhecimento especializado em física na etapa de extração de atributos, além de investigar modelos mais avançados de aprendizado de máquina.

Bibliografia

- 1 BETETA, C. A. et al. *Calibration and performance of the LHCb calorimeters in Run 1 and 2 at the LHC*. 2020. Disponível em: <<https://arxiv.org/abs/2008.11556>>. Referenced on page 14.6 Referenced 1 times on pages 14.
- 2 MARIN, J. et al. Conjunto de redes neurais artificiais para detecção online de fótons de altas energias. In: *Anais do 15º Congresso Brasileiro de Inteligência Computacional (CBIC)*. Joinville, SC: SBIC, 2021. p. 1–8. Referenced on page 14.6 Referenced 1 times on pages 14.
- 3 OLÍMPICOS, J. V. C. S. P. *Uma Breve Introdução ao Modelo Padrão da Física de Partículas*. [S.l.: s.n.]. Referenced on page 14.6 Referenced 1 times on pages 14.
- 4 CERN. *CERN Timeline*. 2025. Acesso em: 22 jan. 2025. Disponível em: <<https://timeline.web.cern.ch/timeline-header/90>>.
- 5 MARTIN, B. R. *Nuclear and Particle Physics: An Introduction*. 2. ed. Chichester: John Wiley & Sons, 2013. ISBN 9781118676619. Referenced on page 14.6 Referenced 1 times on pages 14.
- 6 OSTERMANN, F. *Partículas elementares e interações fundamentais I F*. Porto Alegre: Instituto de Física - UFRGS, 2001. (Textos de apoio ao professor de física, 12). 74 p.: il. Referenced on page 14.6 Referenced 1 times on pages 14.
- 7 MOSER, B. *Springer Theses Recognizing Outstanding Ph.D. Research The Beauty and the Boost: A Higgs Boson Tale Measurements of Higgs Boson Production at High Energy in Decays to Bottom Quarks and Their Interpretations with the ATLAS Experiment at the LHC*. [S.l.]: Springer, 2021.
- 8 BRÜNING, O. et al. (Ed.). *The Large Hadron Collider: A Marvel of Technology*. Geneva, Switzerland: CERN, 2009. ISBN 978-92-9083-327-5. Referenced on page 15.6 Referenced 1 times on pages 15.
- 9 ATLAS Collaboration. *The ATLAS Experiment at the CERN Large Hadron Collider*. [S.l.]: IOP Publishing, 2008. S08003–S08003 p.
- 10 ZABI, A. Instrumentation for high energy physics. In: *TES-HEP 2016 – Training in Experimental and Statistical tools for High Energy Physics*. [S.l.: s.n.], 2016. Presentation. Referenced on page 15.6 Referenced 1 times on pages 15.
- 11 Simas Filho, E. et al. Uma Proposta para Calibração do Sistema Online de Seleção de Eventos no Detector ATLAS utilizando Gradient Boosted Decision Trees. In: *Anais do XV Congresso Brasileiro de Inteligência Computacional (CBIC'2021)*. [S.l.: s.n.], 2021.
- 12 Alves, A. S. O. et al. Calibração de energia para a seleção online de elétrons com alta taxa e utilizando um conjunto de árvores de decisão com reforço por gradiente e informação especialista de calorimetria. In: *Anais do XVI Congresso Brasileiro de Inteligência Computacional (CBIC'2023)*. Salvador, BA: [s.n.], 2023.
- 13 ALVES, A. et al. Calibração de energia para a seleção online de elétrons com alta taxa e utilizando um conjunto de árvores de decisão com reforço por gradiente e informação especialista de calorimetria. In: . [S.l.: s.n.], 2023. p. 1–8. Referenced on page 16.6 Referenced 1 times on pages 16.
- 14 FILHO, E. F. S. et al. Ring-like calorimeter information for energy calibration in electron trigger at a highly segmented detector using gradient boosted decision trees. *Journal of Instrumentation*, IOP Publishing for Sissa Medialab, v. 20, n. 06, p. P06051, June 2025.
- 15 CERN. *CERN Member States*. 2025. Acesso em: 22 jan. 2025. Disponível em: <<https://home.cern/about/who-we-are/our-governance/member-states>>. Referenced on page 17.6 Referenced 1 times on pages 17.
- 16 CERN. *About CERN*. 2025. Accessed: 2025-01-25. Disponível em: <<https://www.home.cern/about>>. Referenced on page 17.6 Referenced 1 times on pages 17.
- 17 CARROLL, S. *The Particle at the End of the Universe*. New York: Dutton, 2012.
- 18 GRIFFITHS, D. J. *Introduction to Elementary Particles*. 1st. ed. New York: Wiley-VCH, 1987. Referenced on page 18.6 Referenced 1 times on pages 18.

- 19 CERN. *Technology Meets Research: 60 Years of CERN Technology - Selected Highlights*. Geneva, Switzerland: CERN, 2024. Referenced on page 18.6 Referenced 1 times on pages 18.
- 20 EVANS, L. (Ed.). *The Large Hadron Collider: A Marvel of Technology*. Geneva: CERN, 2009. ISBN 9789290833346.
- 21 LINCOLN, D. *The Large Hadron Collider: The Extraordinary Story of the Higgs Boson and Other Stuff That Will Blow Your Mind*. Baltimore: Johns Hopkins University Press, 2014. ISBN 978-1-4214-1351-8.
- 22 CERN. *The CERN accelerator complex in 2019*. 2019. Acesso em: 29 dez. 2024. Disponível em: <<https://cds.cern.ch/record/2684277>>.
- 23 CERN. *Computer generated image of the whole ATLAS detector*. 2008. Acesso em: 29 dez. 2024. Disponível em: <<https://cds.cern.ch/record/1095924>>.
- 24 ARAÚJO, M. V. d. *Filtragem Online Baseada em Calorimetria de Altas Energias e com Alta Taxa de Eventos*. Dissertação (Dissertação (Mestrado)) — Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Elétrica, Rio de Janeiro, 2019. Orientadores: José Manoel de Seixas, Márcia Begalli. Referências bibliográficas: p. 79–88. Referenced on page 20.6 Referenced 1 times on pages 20.
- 25 FILHO, E. F. de S. *Análise Não-linear de Componentes Independentes para uma Filtragem Online Baseada em Calorimetria de Alta Energia e com Fina Segmentação*. Tese (Tese de Doutorado) — Universidade Federal do Rio de Janeiro, COPPE – Programa de Pós-graduação em Engenharia Elétrica, Rio de Janeiro, Brasil, dez. 2010.
- 26 AAD, G. et al. The ATLAS Experiment at the CERN Large Hadron Collider. *JINST*, v. 3, p. S08003, 2008. Also published by CERN Geneva in 2010. Disponível em: <<https://cds.cern.ch/record/1129811>>. Referenced on page 20.6 Referenced 1 times on pages 20.
- 27 ALAPJÁN, V. *Filtragem Online Baseada em Calorimetria de Altas Energias e com Alta Taxa de Eventos*. v. 1, p. 14–16, 2016. Disponível em: <https://sucupira.capes.gov.br/sucupira/public/consultas/coleta/trabalhoConclusao/viewTrabalhoConclusao.jsf?popup=true&id_trabalho=7635650>. Referenced on page 21.6 Referenced 1 times on pages 21.
- 28 CERN. *Computer generated image of the ATLAS inner detector*. 2008. Available at: [urlhttps://cds.cern.ch/record/1095926](https://cds.cern.ch/record/1095926). Accessed on: 30 Dec. 2024.
- 29 CERN. *Event Cross Section in a computer generated image of the ATLAS detector*. 2008. Acesso em: 29 dez. 2024. Disponível em: <<http://cds.cern.ch/record/1096081>>.
- 30 FABJAN, C. W. et al. (Ed.). *Technology Meets Research: 60 Years of CERN Technology – Selected Highlights*. Singapore: World Scientific, 2017. v. 27. (Advanced Series on Directions in High Energy Physics, v. 27). ISBN 978-981-4749-13-8. Disponível em: <<https://cds.cern.ch/record/2219700>>. Referenced on page 22.6 Referenced 1 times on pages 22.
- 31 EVANS, L. (Ed.). *The Large Hadron Collider: A Marvel of Technology*. 2. ed. Lausanne: EPFL Press, 2018. ISBN 978-2-88915-282-7. Referenced on page 23.6 Referenced 1 times on pages 23.
- 32 CERN. *Computer Generated image of the ATLAS calorimeter*. 2008. Acesso em: 29 dez. 2024. Disponível em: <<https://cds.cern.ch/record/1095927>>.
- 33 ATLAS detector and physics performance Volume I Technical Design Report 1 Experiment overview. 1999.
- 34 ATLAS Collaboration. *ATLAS detector and physics performance: Technical Design Report, 1*. Geneva: CERN, 1999. (Technical design report. ATLAS ; 14). CERN-LHCC-99-014; ATLAS-TDR-14. ISBN 9290831413, 9789290831419. Disponível em: <<https://cds.cern.ch/record/391176>>. Referenced on page 24.6 Referenced 1 times on pages 24.
- 35 FREUND, W. S. An Ensemble of Neural Networks for Online Electron Filtering at the ATLAS Experiment. *J. Phys. Conf. Ser.*, v. 1525, n. 1, p. 012076, 2020.
- 36 Uso de aprendizado de máquina para detecção online de fótons de altas energias.
- 37 SCHEFER, M. M. Machine learning techniques for selecting forward electrons ($2.5 < \eta < 3.2$) with the atlas high level trigger. 2023. ATLAS Collaboration. Disponível em: <<https://cds.cern.ch/record/2851302>>. Referenced on page 28.6 Referenced 1 times on pages 28.

- 38 AAD, G. et al. The atlas trigger system for LHC run 3 and trigger performance in 2022. *Journal of Instrumentation*, CERN for the benefit of the ATLAS collaboration, v. 19, n. 06, p. P06029, 2024. Referenced on page 30.6 Referenced 1 times on pages 30.
- 39 BARRUÉ, R.; COLLABORATION the A. *The ATLAS trigger system*. Geneva, Switzerland, 2024. Proceedings of the 11th Annual Conference on Large Hadron Collider Physics (LHCP2023), 22–26 May 2023, Belgrade, Serbia. Disponível em: <<http://cds.cern.ch/record/2886398>>. Referenced on page 30.6 Referenced 1 times on pages 30.
- 40 ATLAS Collaboration. *ATLAS event selection system readies for LHC Run 3*. 2022. Acesso em: 16 jun. 2025. Disponível em: <<https://atlas.cern/updates/briefing/run-3-trigger>>.
- 41 HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. 2. ed. New York: Springer, 2009. ISBN 978-0387848570. Disponível em: <<https://web.stanford.edu/~hastie/ElemStatLearn/>>.
- 42 GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. Cambridge, MA: MIT Press, 2016. Disponível em: <<https://www.deeplearningbook.org/>>.
- 43 FRIEDMAN, J. H. Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, v. 29, n. 5, p. 1189–1232, 2001. Disponível em: <<https://doi.org/10.1214/aos/1013203451>>.
- 44 GÉRON, A. *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. 2. ed. Sebastopol, CA: O'Reilly Media, 2019.
- 45 JAMES, G. et al. *An Introduction to Statistical Learning: with Applications in R*. 2. ed. Springer, 2021. (Springer Texts in Statistics). ISBN 978-1-0716-1417-4. Disponível em: <<https://link.springer.com/book/10.1007/978-1-0716-1418-1>>.
- 46 AAD, G. et al. Using pile-up collisions as an abundant source of low-energy hadronic physics processes in atlas and an extraction of the jet energy resolution. *Journal of High Energy Physics*, Springer Science and Business Media LLC, v. 2024, n. 12, dez. 2024. ISSN 1029-8479. Disponível em: <[http://dx.doi.org/10.1007/JHEP12\(2024\)032](http://dx.doi.org/10.1007/JHEP12(2024)032)>. Referenced on page 39.6 Referenced 1 times on pages 39.
- 47 MAIER, B. et al. Pile-up mitigation using attention. *Machine Learning: Science and Technology*, IOP Publishing, v. 3, n. 2, p. 025012, jun. 2022. ISSN 2632-2153. Disponível em: <<http://dx.doi.org/10.1088/2632-2153/ac7198>>. Referenced on page 39.6 Referenced 1 times on pages 39.
- 48 GARNETT, R. *Bayesian Optimization*. Cambridge University Press, 2018. ISBN 110842578X. Disponível em: <<https://bayesoptbook.com/>>. Referenced on page 39.6 Referenced 1 times on pages 39.
- 49 ARCHETTI, F.; CANDELIERI, A. *Bayesian Optimization and Data Science*. Springer, 2019. (SpringerBriefs in Optimization). ISBN 978-3-030-24494-1. Disponível em: <<https://doi.org/10.1007/978-3-030-24494-1>>. Referenced on page 40.6 Referenced 1 times on pages 40.
- 50 GROOM, D. E.; KLEIN, S. R. Passage of particles through matter. *Prog. Theor. Exp. Phys.*, v. 2022, n. 8, p. 28, 2022. Updated August 2023. Disponível em: <<https://pdg.lbl.gov/2023/reviews/rpp2023-rev-passage-particles-matter.pdf>>.
- 51 METCALF, L.; CASEY, W. Chapter 4 - introduction to data analysis. In: METCALF, L.; CASEY, W. (Ed.). *Cybersecurity and Applied Mathematics*. Boston: Syngress, 2016. p. 43–65. ISBN 978-0-12-804452-0. Disponível em: <<https://www.sciencedirect.com/science/article/pii/B978012804452000004X>>. Referenced on page 42.6 Referenced 1 times on pages 42.
- 52 DEVORE, J. L. *Probabilidade e Estatística para Engenharia e Ciências*. 8ª. ed. São Paulo: Cengage Learning, 2016. Referenced on page 42.6 Referenced 1 times on pages 42.
- 53 DEVELOPERS, L. *LightGBM Documentation: Parameters*. 2024. Acesso em: 24 jul. 2025. Disponível em: <<https://lightgbm.readthedocs.io/en/latest/Parameters.html>>. Referenced on page 43.6 Referenced 1 times on pages 43.

Anexos

ANEXO A – Publications

Este trabalho teve versões aceitas para publicação nos seguintes congressos:

- **CBA 2024 – Congresso Brasileiro de Automática**

Trabalho: *[Asymmetric Topologies Applied to the Energy Calibration of the ATLAS Experiment Online Event Selection System.]*

Data: 24 a 27 de setembro de 2024

Local: Belo Horizonte, MG, Brasil

- **IV Encontro de Primavera da SBF – EPSBF 2024**

Trabalho: *[Informações de Assimetria para Calibração de Medições de Energia em um Detector de Partículas usando Árvores de Decisão.]*

Data: 15 a 18 de outubro de 2024

Local: Rio de Janeiro, RJ, Brasil

- **8th ATLAS Machine Learning Workshop**

Trabalho: *[Calibration of Electron Energy Measurements Using Neural Networks and Ring-Like Calorimeter Features.]*

Data: 2 de abril de 2025

Local: CERN, Genebra, Suíça