



CALORIMETRIA COM FINA SEGMENTAÇÃO PARA A RECONSTRUÇÃO DE JATOS EM ALTAS ENERGIAS

Philipp do Nascimento Gaspar

Tese de Doutorado apresentada ao Programa de Pós-graduação em Engenharia Elétrica, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Doutor em Engenharia Elétrica.

Orientador: José Manoel de Seixas

Rio de Janeiro

Abril de 2022

CALORIMETRIA COM FINA SEGMENTAÇÃO PARA A RECONSTRUÇÃO
DE JATOS EM ALTAS ENERGIAS

Philipp do Nascimento Gaspar

TESE SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO
LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA
DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS
REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR
EM CIÊNCIAS EM ENGENHARIA ELÉTRICA.

Orientador: José Manoel de Seixas

Aprovada por: Prof. José Manoel de Seixas
Prof. Alexandre Gonçalves Evsukoff
Prof. Alexandre Visintainer Pino
Prof. André Massafferri Rodrigues
Prof. Antônio de Pádua Braga
Prof.^a Marcia Begalli
Prof.^a Mariane Rembold Petraglia

RIO DE JANEIRO, RJ – BRASIL
ABRIL DE 2022

Gaspar, Philipp do Nascimento

Calorimetria com Fina Segmentação para a
Reconstrução de Jatos em Altas Energias/Philipp do
Nascimento Gaspar. – Rio de Janeiro: UFRJ/COPPE,
2022.

XIV, 101 p.: il.; 29,7cm.

Orientador: José Manoel de Seixas

Tese (doutorado) – UFRJ/COPPE/Programa de
Engenharia Elétrica, 2022.

Referências Bibliográficas: p. 89 – 99.

1. Calorimetria. 2. Aprendizado de Máquina.
3. Física de Altas Energias. I. Seixas, José Manoel
de. II. Universidade Federal do Rio de Janeiro, COPPE,
Programa de Engenharia Elétrica. III. Título.

*Dedico este trabalho a todos os
adultos que, quando crianças,
sonharam em se tornar
cientistas.*

Agradecimentos

Agradeço principalmente aos meus pais, José Carlos e Mirian, que apesar de todas as adversidades sempre priorizaram a minha educação. O bom humor de meu pai e o carinho e atenção de minha mãe se fizeram fundamentais durante toda essa caminhada.

Agradeço também à minha companheira Gabriela pelos sábios conselhos e pela imensa paciência durante os tempos tortuosos que configuram uma tese de doutorado. Dividir meus dias com você é um privilégio.

Ao meu orientador José Manoel de Seixas por ter aceitado me orientar e me permitir trabalhar em diversas áreas durante nossa colaboração. Sua paciência e dedicação com todos seus alunos é inspiradora. Saudações Alvinegras!

À professora Marcia Begalli por ter me dado a primeira oportunidade de participar de uma colaboração internacional. As portas que me foram abertas há anos atrás guiam minhas decisões profissionais até hoje. Muito obrigado.

À Ana Henriques e ao Oleg Solovyanov por me receberem muito bem no grupo do TileCal e por acreditarem no projeto que culminou com a minha aprovação como autor do CERN; e agora se transforma nesta tese de doutorado.

Aos amigos do Laboratório de Processamento de Sinais (LPS), em especial ao Werner Freund, Victor Ferraz e Rafael Gama por terem sido meus companheiros de apartamento durante os períodos em que passei no CERN. Foi a companhia de vocês que fez Genebra um lugar especial.

Agradeço também aos tantos outros amigos que fiz no LPS durante esses anos: Micael Veríssimo, João Victor, Carlos Costa, Julio Vargas, Natanael Moura, Fernando Ferreira, Rodrigo Torres e ao Luis Frias (que me convidou para ser padrinho de seu casamento).

Por último agradeço à Coppe/UFRJ, instituição da qual tenho o orgulho de pertencer. Farei o meu melhor para fazer jus ao peso que esta formação significa.

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D.Sc.)

CALORIMETRIA COM FINA SEGMENTAÇÃO PARA A RECONSTRUÇÃO DE JATOS EM ALTAS ENERGIAS

Philipp do Nascimento Gaspar

Abril/2022

Orientador: José Manoel de Seixas

Programa: Engenharia Elétrica

Para atender o extenso programa de física estudado pelo experimento LHC, o experimento ATLAS passa por diversas fases de atualização que são cruciais, não só para a manutenção, como também para permitir a completa exploração do potencial físico do experimento. Com o aumento da faixa de energia das colisões, se faz necessária uma granularidade mais fina em seu detector, a fim de possuir resolução suficiente para registrar objetos físicos deste novo regime.

Neste contexto, este trabalho apresenta técnicas de processamento de sinais, em conjunto com algoritmos de aprendizado de máquina, para tornar mais fina a granularidade do calorímetro de telhas do ATLAS, sem a necessidade de modificar sua parte mecânica; adicionando uma fotomultiplicadora com leitura multi-anodal, alterando apenas a parte ótica e sua eletrônica de leitura.

Um conjunto de dados reais e sintéticos é utilizado para mapear a imagem formada na grid de pixels da fotomultiplicadora em regiões topológicas no calorímetro, permitindo que a sua segmentação se torne duas vezes mais fina. Resultados de classificação obtiveram índice $SP = 96,8 \pm 0,5$ para uma nova granularidade transversal e $SP = 98,5 \pm 0,4$ para uma granularidade longitudinal, permitindo a operação do detector no novo ambiente de atualização.

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

FINE-GRAINED CALORIMETRY FOR HIGH-ENERGY JET RECONSTRUCTION

Philipp do Nascimento Gaspar

April/2022

Advisor: José Manoel de Seixas

Department: Electrical Engineering

To meet the extensive physics program studied by the LHC experiment, the ATLAS experiment goes through several upgrade phases that are crucial, not only for maintenance, but also to allow the full exploitation of the experiment's physical potential. With the increase in the energy range of the collisions, a thinner granularity is required in its detector, in order to have sufficient resolution to record physical objects of this new regime.

In this context, this work presents signal processing techniques, together with machine learning algorithms, to make the granularity of the ATLAS tile calorimeter thinner, without the need to modify its mechanical part; adding a photomultiplier with multi-anodal reading, changing only the optical part and its reading electronics.

A set of real and synthetic data are used to map the image formed in the photomultiplier's pixel grid into topological regions inside the calorimeter, allowing its segmentation to become twice as thinner. Classification results obtained index $SP = 96.8 \pm 0.5$ for a new transverse granularity and $SP = 98.5 \pm 0.4$ for a longitudinal granularity, allowing detector operation in the new update environment .

Sumário

Lista de Figuras	x
Lista de Tabelas	xiv
1 Introdução	1
1.1 Motivação	1
1.2 Objetivo	4
1.3 Contribuição do Trabalho	5
1.4 Organização do Texto	6
2 O Experimento ATLAS no LHC	7
2.1 Física de Altas Energias	7
2.2 O Modelo Padrão	9
2.3 O Grande Colisor de Hádrons (LHC)	11
2.4 O Experimento ATLAS	13
2.4.1 Sistema de Coordenadas	15
2.5 O Calorímetro Hadrônico de Telhas	16
3 Calorimetria no TileCal	17
3.1 Cadeia de Leitura	17
3.2 Reconstrução do Sinal	18
3.3 Segmentação do Calorímetro	19
3.4 Conjunto de Fibras	20
3.5 Sistema de Calibração	22
3.5.1 Sistema de Césio	22
3.5.2 Sistema de Laser	24
3.5.3 Sistema de Injeção de Carga	24
3.6 Atualização Para a Nova Luminosidade	25
4 Física de Jatos de Partículas	28
4.1 Simulações de Monte Carlo para Jatos de Partículas	29
4.2 Reconstrução de Jatos	30

5	Nova Proposta de Segmentação	33
5.1	Melhorias na Performance	34
5.1.1	Granularidade Longitudinal	35
5.1.2	Granularidade Transversal	35
5.2	Simulações de Monte Carlo para Nova Granularidade	37
5.3	Fotomultiplicadora Multianodal	39
5.4	Acoplamentos Ópticos	41
5.4.1	Sistema de Lentes	42
5.4.2	Guia de Fibras	42
5.5	Testes de Bancada	43
6	Resultados	45
6.1	Dados da Análise	46
6.1.1	Dados da Célula A2	49
6.1.2	Dados da Célula BC1	50
6.2	Proposta de Validação Cruzada	55
6.3	Geração de Dados Sintéticos	55
6.3.1	Redes Generativas Adversariais	56
6.3.2	Imagens Sintéticas para a Célula A2	59
6.3.3	Imagens Sintéticas para a Célula BC1	65
6.4	Pipelines de Classificação	70
6.4.1	Redes Neurais Convolucionais	72
6.4.2	Pipeline I - Dados Sintéticos	72
6.4.3	Pipeline II - Dados Sintéticos e Reais	76
6.4.4	Pipeline III - Ajuste Fino	79
6.5	Resumo da Classificação	82
7	Conclusões	86
8	Trabalhos Futuros	88
	Referências Bibliográficas	89
A	Projeto de <i>Authorship</i> do ATLAS	100
B	Produção Científica	101

Lista de Figuras

2.1	Complexo de aceleradores do CERN. Extraído de [45].	13
2.2	Visão esquemática do detector ATLAS. Extraído de [40].	14
2.3	Sistema de coordenadas do ATLAS.	15
2.4	Módulos do TileCal. Extraído de [40].	16
3.1	Visão esquemática de um dos 64 módulos do TileCal. A figura mostra os materiais absorvedores e cintiladores intercalados entre si, bem como a fibra WLS que vai da telha cintiladora até o tubo fotomultiplicador no final do módulo. Extraído de [58].	18
3.2	Exemplo de pulso formado no TileCal com suas sete amostras. Pedestal, amplitude e fase também podem ser vistos na figura. Extraída de [60].	19
3.3	Módulos central e estendido do TileCal. A segmentação do calorímetro é ditada pelo tamanho de cada uma de suas células. Extraído de [63].	20
3.4	Módulo do barril estendido. Na figura pode-se observar a divisão espacial de cada célula, os tubos fotomultiplicadores acoplados ao final do módulo e cada uma das suas onze fileiras de telhas. Extraído de [64].	21
3.5	Aglomerado de fibras acoplado ao seu misturador de luz. Extraído de [58].	21
3.6	Diagrama dos diferentes sub-sistemas de calibração presentes no TileCal. Extraído de [66].	23
3.7	Varição da resposta do sistema de calibração de Césio do TileCal durante o Run II. Extraído de [68].	23
3.8	Varição média (%) das células do TileCal medidas com o sistema de calibração por Laser durante o período de 2018. Extraído de [70].	24
3.9	Médias das constantes de calibração CIS para todos os canais durante o Run II. Extraído de [70].	25

3.10	Plano base para a operação do LHC pelos próximos 20 anos. Após o terceiro grande desligamento (<i>long shutdown</i>), o acelerador entrará na nova configuração chamada HL-LHC. Extraído de [76].	27
4.1	Visão pictórica da reconstrução de jatos de partículas no calorímetro de telhas do ATLAS (TileCal).	32
5.1	Colimação de partículas em um único jato por conta do <i>boost</i> de momento sofrido pela partícula original.	36
5.2	Separação angular entre os quarks produzidos no decaimento $Z' \rightarrow t\bar{t}$, onde cada quark top decai em $t \rightarrow Wb$ em função de p_T^W . Extraída de [101].	37
5.3	Resolução de jatos com grande R em função do momento transverso p_T^{jet} para o barril central, esquerda, e para o barril estendido, direita. Extraído de [104].	38
5.4	Número de elementos em grandes jatos, provenientes do decaimento do bóson W' para a geometria atual e modificada ($\Delta\eta \times \Delta\phi = 0,025 \times 0,1$).	39
5.5	Estrutura básica de um tubo fotomultiplicador. Seus componentes essenciais são o fotocatodo, a ótica de focalização dos elétrons, os dinodos e o anodo. Extraído de [107].	40
5.6	A primeira fotomultiplicadora, da esquerda para a direita, possui leitura multianodal com 64 foto sensores distribuídos em uma grade de 8×8 <i>pixels</i> (modelo R7600). Ao lado, temos duas fotomultiplicadoras de anodo único, fabricadas especialmente para o TileCal (modelo R7877).	41
5.7	Representação em escala da face exterior de um conjunto de fibras.	41
5.8	Ampliação da imagem formada pelo conjunto de fibras através de um sistema de lentes.	42
5.9	Guia de Fibras produzido pela impressora 3D.	43
5.10	Amplitude média de sinal para diferentes acoplamentos ópticos, em função da sua distância com a MA-PMT.	44
6.1	Nova granularidade, transversal e longitudinal. A linha em azul é uma representação da nova divisão das células BC1 e A2 que pode se estender para o restante das células nas suas respectivas camadas.	46
6.2	Capsula de Césio, usada durante a calibração, dentro de um dos tubos por onde ela navega.	47
6.3	Fluxo percorrido pela cápsula de material radioativo, ^{137}Cs , ao passar pelas telhas do TileCal durante a calibração. Extraída de [121].	47

6.4	Sinal temporal para a primeira fileira da célula A12. Observamos nove picos, cada um deles corresponde à passagem da fonte de Césio por dentro de cada telha presente na fileira.	48
6.5	Instalação dos conjuntos de fibras, e seus misturadores de luz, na parte externa de um dos módulos do TileCal.	48
6.6	Sinal temporal para os três tubos que compõe a célula A2.	53
6.7	Sinal temporal para os seis tubos que compõe a célula BC1.	54
6.8	Exemplo da validação cruzada usada no trabalho. A figura mostra as duas primeiras partições para a validação aplicada nos dados da célula A2.	56
6.9	Representação de como os modelos Gerador e Discriminador são treinados simultaneamente no modelo adversarial.	57
6.10	Comparação entre imagens reais (a) e sintéticas (b) para a parte esquerda da célula A2.	60
6.11	Comparação entre imagens reais (a) e sintéticas (b) para a parte direita da célula A2.	61
6.12	Erro médio, calculado pixel à pixel, entre imagens reais e sintéticas para a sub-célula esquerda (a) e direita (b) da célula A2.	62
6.13	Erro relativo entre as classes esquerda e direita para imagens reais (a) e sintéticas (b).	63
6.14	Intensidade de pixels reais (azul) e sintéticos (vermelho) para as sub-células esquerda (a) e direita (b) da célula A2.	64
6.15	Comparação entre imagens reais (a) e sintéticas (b) para a sub-célula B.	65
6.16	Comparação entre imagens reais (a) e sintéticas (b) para a sub-célula C.	66
6.17	Erro médio, calculado pixel à pixel, entre imagens reais e sintéticas para a sub-célula B (a) e C (b) da célula BC1.	67
6.18	Erro relativo entre as classes B e C para imagens reais (a) e sintéticas (b).	68
6.19	Intensidade de pixels reais (azul) e sintéticos (vermelho) para as sub-células B (a) e C (b) da célula BC1.	69
6.20	Esquema dos pipelines de análise. A seta em azul representa os pipelines de classificação que também usam dados reais em sua composição	71
6.21	Resultados da classificação para a célula A2 no Pipeline I.	73
6.22	Intensidade de pixels das imagens da célula A2 classificadas erroneamente no Pipeline I.	74
6.23	Eficiência de classificação da célula A2 no Pipeline I.	74
6.24	Resultados da classificação para a célula BC1 no Pipeline I.	75

6.25	Intensidade de pixels das imagens da célula BC1 classificadas erroneamente no Pipeline I.	75
6.26	Eficiência de classificação da célula BC1 no Pipeline I.	76
6.27	Resultados da classificação para a célula A2 no Pipeline II.	77
6.28	Intensidade de pixels das imagens da célula A2 classificadas erroneamente no Pipeline II.	77
6.29	Eficiência de classificação da célula A2 no Pipeline II.	78
6.30	Resultados de classificação para a célula BC1 no Pipeline II.	78
6.31	Intensidade de pixels das imagens da célula BC1 classificadas erroneamente no Pipeline II.	79
6.32	Eficiência de classificação da célula BC1 no Pipeline II.	79
6.33	Resultados da classificação para a célula A2 no Pipeline III.	80
6.34	Intensidade de pixels das imagens da célula A2 classificadas erroneamente no Pipeline III.	81
6.35	Eficiência de classificação da célula A2 no Pipeline III.	81
6.36	Resultados da classificação para a célula BC1 no Pipeline III.	82
6.37	Intensidade de pixels das imagens da célula BC1 classificadas erroneamente no Pipeline III.	82
6.38	Eficiência de classificação da célula BC1 no Pipeline III.	83
6.39	Concordância (azul) e discordância (vermelho) entre os pipelines I e III para as sub-células Esquerda (a) e Direita (b) da célula A2.	84
6.40	Concordância (azul) e discordância (vermelho) entre os pipelines I e III para as sub-células B (a) e C (b) da célula BC1.	85

Lista de Tabelas

2.1	Léptons detectados experimentalmente e o ano de suas descobertas [14].	10
2.2	Propriedades das três famílias de quarks juntamente com o ano de suas descobertas [14]. A massa do quark <i>top</i> corresponde à média mundial atual [21].	10
2.3	Partículas mediadoras das forças forte, fraca e eletromagnética, juntamente com suas massas e o ano de descoberta	11
3.1	Número de fibras em cada uma das células do TileCal.	22
6.1	Número de eventos para cada varredura realizada na célula A2. A letra F significa que o scan foi de ida, enquanto a letra B significa que o scan foi feito durante a volta da cápsula ao seu ponto inicial.	49
6.2	Número de eventos para cada varredura realizada na célula BC1. A letra F significa que o scan foi de ida, enquanto a letra B significa que o scan foi feito durante a volta da cápsula ao seu ponto inicial.	51
6.3	Arquitetura usada na rede Geradora.	58
6.4	Arquitetura usada na rede Discriminadora.	58
6.5	Arquitetura usada na Rede Convolutacional de Classificação.	72
6.6	Performance de classificação para a célula A2.	83
6.7	Performance de classificação para a célula BC1.	83

Capítulo 1

Introdução

Em ambientes de instrumentação eletrônica, na maioria das ocasiões, sensores são empregados para obter uma medição experimental de um ou mais valores que podem ser atribuídos à uma grandeza física. Há também situações onde o mesmo objeto de estudo possui suas informações sendo caracterizadas por sensores com características distintas. Neste caso, diz-se que a informação encontra-se segmentada. Arranjos deste tipo não são incomuns e podem ser vistos em diversas aplicações de processamento de sinais.

Em geral, ambientes com uma quantidade elevada de informação, e elevada taxa de amostragem, são instrumentalizados de maneira finamente segmentada. Dependendo da complexidade de tal objeto, uma fina segmentação é utilizada, de modo que a correspondente granularidade dos sensores promova a riqueza de detalhes exigida.

Quando o arranjo experimental não possui a granularidade exigida para a medição, seja por motivos relacionados à instrumentação ou ao legado histórico do experimento, podemos utilizar técnicas de inteligência computacional, juntamente com o conhecimento especialista da área, para criar uma nova segmentação sem que seja necessária uma nova instrumentalização.

1.1 Motivação

A matéria tangível do nosso cotidiano se manifesta em baixas energias; no entanto, para estudar a estrutura interna da matéria, ou seja, suas partículas fundamentais, precisamos criar artificialmente condições que viabilizem sua manifestação em altíssimas energias. Para realizar tal tarefa, a comunidade científica passou a projetar máquinas de grande porte, conhecidas como Aceleradores de Partículas, de modo a investigar não só os blocos fundamentais que constituem a natureza, como também questões relacionadas à origem do universo e outros ramos da física. Logo, a Física de Altas Energias, como é chamada, tem como objetivo desvendar as regras básicas que permeiam as relações entre a matéria e as leis que regem seus processos naturais.

O Centro Europeu de Pesquisas Nucleares (*Conseil Européen pour la Recherche Nucléaire - CERN*), localizado em Genebra, possui o maior e mais poderoso acelerador de partículas da história, O Grande Colisor de Hádrons (*Large Hadron Collider - LHC*). Possuindo uma geometria circular de 27 km de circunferência e localizado a 100 m abaixo do solo, o LHC colide feixes de prótons com energia de até 14 TeV. Durante as colisões a energia cinética dos prótons é convertida na formação de novas partículas, um exemplo direto da famosa equação de Einstein, $E = mc^2$, que relaciona energia e massa.

Para detectar o produto destas colisões, o LHC conta com quatro experimentos de grande porte, destacando-se o maior deles, o ATLAS (*A Toroidal LHC ApparatuS*), objeto de estudo desta tese, que possui 44 m de comprimento, 25 m de diâmetro e 7000 toneladas, distribuídas em seu formato cilíndrico ao redor de um dos pontos de colisão. A construção do ATLAS é o resultado de uma colaboração internacional, com mais de 3000 pesquisadores, envolvendo 172 institutos provenientes de 38 países diferentes.

No dia 4 de Julho de 2012, os experimentos ATLAS e CMS anunciaram a descoberta de uma nova partícula com propriedades físicas consistentes com o Bóson de Higgs, uma partícula proposta teoricamente em 1964 por Peter Higgs e François Englert, responsável pelo mecanismo que contribui com a compreensão de como objetos subatômicos adquirem massa, culminando com a entrega do Prêmio Nobel de Física de 2013 ao belga Englert e ao britânico Higgs por seus trabalhos teóricos.

A comunidade científica brasileira participa dos trabalhos do CERN desde a sua criação, em 1954. Segundo dados da organização, em 2019, 112 pesquisadores brasileiros utilizaram a infraestrutura do CERN para desenvolver seus estudos. Mas foi em Setembro de 2021, através do Ministério da Ciência, Tecnologia e Inovações (MCTI), que o Brasil foi aceito como um dos países membros do CERN, sendo, até a presente data, o único país das Américas e do hemisfério sul a ser membro da organização.

Para atender a demanda do programa de física proposto pelo CERN, o LHC passa por atualizações ao longo dos anos. Separadas por fases, a primeira fase de *upgrade* ocorreu entre meados de 2018 até o final de 2019. Já a segunda fase de atualizações está agendada para acontecer entre 2023 e o segundo semestre de 2025. Esta fase será responsável por colocar o LHC em regime de alta luminosidade¹ (*High Luminosity Large Hadron Collider - HL-LHC*).

Aumentar a luminosidade do LHC significa, em poucas palavras, aumentar a taxa de colisões por intervalo de tempo. Ou seja, esta atualização irá permitir que os experimentos ampliem a sua taxa de eventos em uma ordem de magnitude maior

¹Luminosidade é a taxa de eventos para uma determinada seção de choque. Possui unidade de eventos, por tempo, por área.

que a luminosidade atual do acelerador. A linha de tempo do projeto de *upgrade* é ditada pelo fato de que muitos componentes críticos do acelerador chegarão ao fim da sua vida útil devido a danos de radiação e, portanto, precisam ser substituídos. A fase de atualização é crucial não apenas para a plena exploração do potencial físico do LHC, como também para permitir a operação do colisor pelas próximas décadas.

O experimento ATLAS é composto por subdetectores responsáveis por realizar as medidas de energia e da trajetória das partículas provenientes das colisões próton-próton. Os sistemas encarregados das medições de energia são chamados de Calorímetros, eles medem a perda de energia dessas partículas ao passarem pelo detector e são, usualmente, projetados para absorver a maioria delas, forçando-as a depositar toda a sua energia dentro do aparato. Logo, podemos dizer que os calorímetros possuem métodos destrutivos de detecção, em razão da absorção total da partícula para o cálculo de sua energia.

O calorímetro de Telhas Cintiladoras (*Tile Calorimeter - TileCal*) é o principal calorímetro hadrônico do ATLAS e utiliza placas de ferro como material absorvedor, intercaladas com telhas de material plástico cintilante, como meio ativo. As partículas que passam pelo TileCal interagem com o núcleo do material absorvedor produzindo uma cascata de novas partículas, neutras e carregadas, que por sua vez ionizam o material cintilador (telhas) produzindo uma luz ultravioleta. O sinal luminoso resultante é levado através de fibras óticas, para tubos fotomultiplicadores, que convertem tal sinal luminoso em um pulso elétrico.

As telhas cintiladoras do TileCal são agrupadas com o objetivo de formar as células do calorímetro. Assim, o TileCal possui uma resolução geométrica que é determinada pelo tamanho de suas células e a quantidade de fibras acopladas às suas fotomultiplicadoras. Ou seja, o calorímetro é segmentado, com a sua granularidade dada pelo tamanho físico de cada uma de suas células.

Durante a segunda fase do *upgrade*, o TileCal contará com uma substituição completa da sua eletrônica. Com isso, há uma possibilidade técnica de utilizar informações individuais de cada uma das telhas, a fim de tornar mais fina a granularidade do detector, modificando apenas a leitura do seu sinal óptico, sem alterar sua parte mecânica. Para isto, deseja-se empregar, para cada célula, um tubo fotomultiplicador com capacidade de leitura multianodal, substituindo a atual fotomultiplicadora de anodo único, sendo possível ler o sinal de cada fibra individualmente e, assim, obter informação adicional da distribuição de energia depositada numa célula.

Uma atualização no sistema de calorimetria do TileCal se mostra fundamental para a continuidade do programa de física do ATLAS. Um exemplo é a medida de jatos de partículas² que aparecem no decaimento de eventos raros, como o Bóson de Higgs, e em outros processos físicos importantes. Jatos com alto momento trans-

²Conjunto de partículas colimadas em uma estrutura no formato de cone.

verso³ tendem a depositar sua energia em camadas mais profundas do calorímetro.

Portanto, ao dividir estas células em diferentes sub-regiões, será possível adquirir com mais detalhes o perfil longitudinal destes objetos físicos. Além disso, melhorias na reconstrução de momento, massa e posição angular, também serão beneficiadas com um ambiente de granularidade mais fina.

1.2 Objetivo

Este trabalho acontece dentro da colaboração entre o Laboratório de Processamento de Sinais (LPS) e o experimento ATLAS. Os esforços são concentrados para aprimorar a reconstrução de jatos de partículas de altas energias detectados após o processo de atualização do detector. Para isso contamos com pesquisa e desenvolvimento em diferentes âmbitos como: instrumentação, processamento de sinais, aprendizado de máquina e métodos estatísticos.

O objetivo principal é tornar mais fina a granularidade do TileCal sem alterar a sua estrutura mecânica, modificando apenas sua cadeia de leitura e sua parte ótica. Ao substituímos as fotomultiplicadoras de anodo único por novas fotomultiplicadoras com leitura multi-anodal (*Multi Anode Photomultiplier Tube - MA-PMT*), temos então um sinal luminoso composto 64 foto-sensores dispostos em uma matriz de 8×8 pixels.

Utilizando o conhecimento especialista sobre a cadeia de leitura do TileCal, juntamente com sua geometria, desenvolvemos métodos, baseados em aprendizado de máquina, capazes de associar um padrão de imagem formado na MA-PMT à uma região topológica específica dentro das células do calorímetro. Esse processo permite tornar a granularidade do detector duas vezes mais fina do que a configuração atual. Fornecendo uma reconstrução mais precisa de medições físicas no ambiente de alta luminosidade previsto para o *upgrade*, sem a necessidade de modificar a estrutura mecânica do detector.

Este trabalho foi base de um processo de *authorship* do ATLAS, cumprido pelo o autor desta tese. Esta atividade foi feita sob a supervisão de um orientador local e outro pesquisador do próprio experimento. Durante este período, todas as contribuições foram apresentadas para a colaboração ATLAS proporcionando um acompanhamento de todo o desenvolvimento do projeto. A aprovação do candidato no processo de *authorship* configura o reconhecimento do seu trabalho como sendo essencial ao experimento.

³Momento perpendicular ao eixo do feixe.

1.3 Contribuição do Trabalho

A existência da possibilidade de tornar mais fina a granularidade do principal calorímetro hadrônico do detector ATLAS, modificando apenas sua cadeia de leitura, sem necessidade de alterar sua estrutura mecânica, guiou os estudos presentes neste trabalho. A nova segmentação irá permitir que o CERN, através do LHC, acesse com maior resolução os processos físicos que apareceram no regime de alta luminosidade.

A solução apresentada aqui abrange aspectos de instrumentação ao estudar diferentes acoplamentos ópticos para a nova cadeia de leitura, e também ao coletar dados com a nova fotomultiplicadora de leitura multi-anodal. Os dados deste trabalho são oriundos de um dos sistemas de calibração do TileCal; e através do conhecimento da instrumentação e geometria do experimento, foi possível criar um banco de dados anotado que serviu para o treinamento dos algoritmos de classificação associarem uma imagem da nova fotomultiplicadora à uma região do detector.

A coleta dos dados utilizados nesse trabalho exige um longo período de tempo e mão de obra especializada, que após diversas rodadas de aquisição constitui em apenas centenas de eventos por célula do calorímetro; uma estatística extremamente limitada para ser usada em algoritmos de classificação baseados em Aprendizado Profundo (*Deep Learning*). Neste sentido, o presente trabalho também contribui com um método de geração de dados sintéticos que completam a estatística do conjunto de treinamento usado para otimizar o algoritmo de classificação.

Ao final do processo desenvolvemos três *pipelines* de classificação, combinando dados reais e sintéticos e avaliando como suas características impactam as medidas de performance. O resultado final permite dobrar a segmentação atual do TileCal para duas camadas do calorímetro, produzindo, desta maneira, importantes contribuições para o programa de atualização do ATLAS, além de servir como fundação para futuros detectores baseados em processos de calorimetria.

A coleta dos dados, bem como os testes de bancada com a nova instrumentação, foram todos realizados no CERN com a participação pessoal do autor deste trabalho. A problemática relacionada à granularidade atual do TileCal já vinha sendo discutida internamente no grupo, por conta das atualizações e aumentos de energia no LHC. Porém, foi a experiência do Laboratório de Processamento de Sinais (LPS/COPPE), em projetos que envolvem aprendizado de máquina, que permitiu a pesquisa e o desenvolvimento da solução apresentada neste documento.

A concepção da solução, bem como a obtenção dos resultados da pesquisa, foram todos obtidos pelo o autor da tese durante seu processo de doutoramento. Apresentações periódicas foram feitas tanto no grupo do TileCal, quanto internamente no LPS, durante o processo de *authorship* do ATLAS.

1.4 Organização do Texto

- O Capítulo 2 traz uma introdução à Física de Altas Energias, ao Modelo Padrão de Física de Partículas e ao experimento ATLAS; apresentando um resumo da área de estudo deste trabalho e seu aparato experimental.
- No Capítulo 3, encontra-se uma explicação da cadeia de leitura do Calorímetro Hadrônico de Telhas (TileCal), passando por sua eletrônica, segmentação e sistemas de calibração. O capítulo termina com uma seção sobre a nova fase de atualização do experimento.
- O Capítulo 4 descreve a importância dos jatos de partículas para ambientes de física de altas energias, bem como são simulados e reconstruídos pelo calorímetro hadrônico.
- O Capítulo 5 contém a cadeia de leitura e instrumentação para o novo ambiente de granularidade. Simulações de Monte Carlo são utilizadas para compor a motivação física; também apresentamos um panorama dos acoplamentos ópticos disponíveis.
- O Capítulo 6 mostra as técnicas utilizadas para realizar o mapeamento do sinal vindo de um subconjunto de fibras, em novas sub-células do calorímetro de telhas. Uma breve descrição de cada algoritmo é dada, e, em seguida, seus resultados são apresentados e comentados.
- O Capítulo 7 termina o documento com as conclusões sobre o trabalho e o Capítulo 8 com as oportunidades de trabalhos futuros.

Capítulo 2

O Experimento ATLAS no LHC

O CERN foi fundado em 1954 com a missão de estabelecer uma organização, de renome mundial, para a pesquisa em Física na Europa. Naquela época, a pesquisa em Física Pura se concentrava na compreensão do interior do átomo, daí a palavra *nuclear* em seu nome. Hoje em dia, a compreensão da matéria vai muito além do núcleo, e a principal área de pesquisa do CERN é a Física de Partículas, que consiste no estudo dos constituintes fundamentais da matéria e das forças que atuam entre eles [1, 2].

Os instrumentos utilizados no CERN são os aceleradores e detectores de partículas construídos especificamente para seus experimentos. Aceleradores impulsionam os feixes de partículas até atingirem altas energias, em seguida estes feixes são colididos entre si ou com alvos fixos. Presentes ao redor de onde ocorrem as colisões, os detectores têm como papel principal registrar o produto dessas interações [3].

Além dos experimentos de física de altas energias, o CERN também desenvolve equipamentos e tecnologias que são utilizados em diversas áreas do conhecimento científico. Como, por exemplo, a invenção do protocolo *World Wide Web*, o desenvolvimento de detectores para visualização de imagens em medicina, equipamentos de radioterapia, tecnologias de computação em nuvem e, inclusive, aplicações aeroespaciais. Este capítulo possui uma breve introdução sobre área de física de partículas elementares e também descreve o acelerador LHC e seu experimento ATLAS, com maior ênfase em seu sistema de calorimetria.

2.1 Física de Altas Energias

Como foi dito na seção 1.1, para estudar a estrutura da matéria no seu nível mais fundamental, precisamos criar artificialmente condições que viabilizem a sua manifestação em altíssimas energias. Neste contexto surge a Física de Altas Energias, responsável por estudar uma variedade de fenômenos relacionados à estrutura da matéria e suas interações [4]. A nomenclatura *altas energias* pode ser compreendida

quando consideramos a principal característica de seus experimentos: a energia do feixe de partículas.

Não podemos utilizar luz visível para explorar estruturas atômicas e sub-atômicas. Entretanto, como todas as partículas possuem propriedades ondulatórias, podemos usá-las como sondas. De acordo com a equação de de Broglie, a relação entre o momento $|p|$ e o comprimento de onda λ de um pacote de onda é dado por

$$\lambda = \frac{\tilde{h}}{|p|}, \quad (2.1)$$

onde h é a constante de Planck [5].

Como o comprimento de onda é inversamente proporcional ao momento, para investigar a estrutura sub-atômica da matéria precisamos que essas partículas possuam o menor comprimento de onda possível, ou seja, se pretendemos utilizar o acelerador como um enorme *microscópio*, sua resolução deve aumentar com a energia do feixe, permitindo o acesso a estruturas de dimensões cada vez menores. A equação 2.1 representa uma relação fundamental, ela nos diz que a resolução aumenta com a energia do feixe.

Adicionalmente, é possível usar os aceleradores para colidir dois feixes de partículas e produzir novas partículas com massa maior que as originais. Pois durante a colisão, a energia cinética pode ser convertida em novas partículas, algumas tão instáveis que duram menos de um bilionésimo de segundo antes de decaírem em partículas mais estáveis. Einstein provou que energia e massa são dois lados da mesma moeda, e a conversão de uma em outra pode ser descrita pela sua famosa equação

$$E = mc^2. \quad (2.2)$$

Também, por conta desta equivalência, massa e energia podem ser medidas na mesma unidade. Na escala da física de partículas essa unidade é o elétron-Volt (eV) e seus múltiplos keV (10^3 eV), MeV (10^6 eV), GeV (10^9 eV) e o TeV (10^{12} eV). O elétron-Volt é conveniente porque as energias que os físicos de partículas trabalham são muito pequenas quando comparadas com as unidades usadas na mecânica clássica por exemplo. No LHC, descrito na seção 2.3, a energia total de colisão pode chegar até 14 TeV no seu centro de massa, e isso faz dele o acelerador de partículas mais poderoso do mundo. Ainda assim, se convertermos essa energia para Joules teremos:

$$14 \times 10^{22} \times 1,602 \times 10^{-19} = 22,4 \times 10^{-7} \text{ J.}$$

A definição de elétron-Volt vem do fato que um elétron acelerado por uma diferença de potencial de 1 V terá uma quantidade discreta de energia $E = qV$, onde q é a carga do elétron em Coulombs e V é a diferença de potencial em Volts. Assim

$$1 \text{ eV} = (1,602 \times 10^{-19} \text{ C}) \times (1 \text{ V}) = 1,602 \times 10^{-19} \text{ J}.$$

2.2 O Modelo Padrão

Grande parte dos dados coletados em experimentos de física de partículas são usados para descrever o chamado Modelo Padrão (em inglês, *Standard Model - SM*) [6]. Trata-se de um modelo matemático que busca desvendar as interações responsáveis por mediar a dinâmica das partículas sub-atômicas. Desenvolvido na metade do século XX, e com sua formulação atual tendo confirmações até hoje, o Modelo Padrão é tão importante para os físicos teóricos quanto para os experimentais.

Para os teóricos, o Modelo Padrão é o exemplo de uma teoria quântica de campos, que apresenta uma ampla variedade de assuntos como: quebra espontânea de simetria, anomalias, comportamento não perturbativo e etc. Por outro lado, os físicos experimentais incorporam o Modelo Padrão em simulações de Monte Carlo [7] de forma a comparar seus resultados experimentais com o que foi previsto, ou não, pela teoria. Porém, há também uma tentativa de explicar os resultados em desacordo com o Modelo Padrão, para este tipo de busca dá-se o nome de Física Além do Modelo Padrão (*Physics Beyond the Standard Model - BSM*), onde encontramos modelos que incorporam partículas hipotéticas, dimensões extras, matéria e energia escura e supersimetria [8].

Historicamente, antes do início deste ramo da física, a existência de diversos elementos químicos já era conhecida. Estes elementos encontravam-se organizados na Tabela Periódica [9, 10] através de características como: número atômico, configuração de elétrons e outras propriedades químicas. Esta simplificação foi possível por conta da descoberta de que todos os átomos eram compostos por apenas três partículas: prótons, elétrons e nêutrons. Ao adicionar ou subtrair uma combinação destas partículas era possível obter diferentes tipos de elementos químicos.

Este cenário começou a ficar confuso quando, no início do século XX, foram detectadas novas partículas provenientes de raios cósmicos¹ [11]. Como não havia um sistema para a organização da nova quantidade de partículas que eram encontradas nos raios cósmicos, uma nova classificação foi criada de acordo com novas propriedades, são elas: o spin^2 , carga elétrica, massa e tempo de vida média. Para simplificar este novo modelo, partículas elementares chamadas de quarks foram propostas [12].

Mais especificamente, o Modelo Padrão descreve toda a matéria como sendo composta por partículas elementares chamadas de férmions, partículas com spin semi-inteiro, assim chamadas pois obedecem a estatística de Fermi-Dirac. Os férmio-

¹Radiação altamente energética, geralmente originada fora do sistema solar. Ao cruzar a atmosfera terrestre, os raios cósmicos podem produzir uma cascata de partículas secundárias que atingem a superfície terrestre. Sua energia varia entre 10^8 e 10^{19} eV.

²Uma forma intrínseca de momento angular de uma partícula elementar

ons são classificados de acordo com a maneira que interagem, ou por quais cargas eles transportam [2]. Entre os férmions existem os quarks e léptons que se manifestam em três gerações, ou famílias. Quarks [13] são partículas de carga elétrica fracionária e aparecem em seis *sabores* (*flavours*): *up*, *down*, *strange*, *charm*, *top* e *bottom*. Partículas compostas por quarks são chamadas de hádrons, um exemplo é o próton que é composto por dois quarks *up* e um quark *down* (*uud*). Léptons podem possuir carga nula como é o caso do neutrino (ν) ou carga elétrica inteira como é o caso do múon (μ), elétron (e) e o tau (τ). Um sabor diferente de cada neutrino está associado à cada família dos léptons carregados, ou seja, temos o neutrino do elétron (ν_e), neutrino do múon (ν_μ) e o neutrino do tau (ν_τ).

A matéria ordinária, que observamos no nosso dia a dia, é composta por partículas pertencentes às primeiras gerações, tanto de léptons, com exceção do neutrino do elétron, quanto de quarks. Partículas pertencentes à segunda e terceira gerações, devido ao curto tempo de vida média, somente podem ser observadas nas condições criadas pelos experimentos de altas energias. As Tabelas 2.1 e 2.2 mostram uma visão geral destas partículas elementares, bem como o ano de suas descobertas.

Tabela 2.1: Léptons detectados experimentalmente e o ano de suas descobertas [14].

Geração	Lépton	Carga [e]	Massa [MeV]	Data da Descoberta
I	e	-1	0,511	1897 [15]
	ν_e	0	$< 2 \times 10^{-6}$	1956 [16]
II	μ	-1	105,658	1936 [17]
	ν_μ	0	$< 0,19$	1962 [18]
III	τ	-1	$1776,86 \pm 0,12$	1975 [19]
	ν_τ	0	$< 18,2$	2000 [20]

Tabela 2.2: Propriedades das três famílias de quarks juntamente com o ano de suas descobertas [14]. A massa do quark *top* corresponde à média mundial atual [21].

Geração	Quark	Carga [e]	Massa	Data da Descoberta
I	u	+2/3	$2,3_{-0,5}^{+0,7}$ MeV	1968 [22, 23]
	d	-1/3	$4,8_{-0,3}^{+0,5}$ MeV	1968 [22, 23]
II	c	+2/3	$1,275 \pm 0,025$ GeV	1974 [24, 25]
	s	-1/3	95 ± 5 MeV	1968 [22, 23]
III	t	+2/3	$173,34 \pm 0,76$ GeV	1995 [26, 27]
	b	-1/3	$4,18 \pm 0,03$ GeV	1977 [28]

Além dos léptons e quarks, existe um terceiro grupo de partículas conhecidas como bósons de Gauge. Essas partículas, de spin inteiro, são responsáveis por mediar as quatro interações fundamentais que o Modelo Padrão busca descrever. Partículas com carga elétrica elétrica interagem via força eletromagnética, que é mediada pelo

fóton (γ). A força fraca tem como mediadores os bósons W^\pm e Z^0 . Estes bósons atuam através de distâncias pequenas, pois possuem uma massa maior comparada com a dos outros bósons. A gravidade foi teorizada para ser mediada através de uma partícula chamada gráviton, porém, até os dias atuais, nenhuma teoria quântica para a gravitação foi confirmada pela detecção experimental do gráviton.

A força forte age entre os quarks garantindo coesão e estabilidade no núcleo atômico. Esta força é mediada pelos glúons, que não possuem massa nem carga elétrica, porém possuem uma diferente característica chamada *carga de cor* [29]. Assim, quarks aparecem em três cores: vermelho, verde e azul. Enquanto os antiquarks aparecem como ciano (antivermelho), magenta (antiverde) e amarelo (antiazul). Somente partículas cuja a combinação de seus constituintes elementares resultam em branco ou sem cor (*colorless*) são permitidas de existirem livremente na natureza.

Por exemplo, partículas contendo três quarks, também chamadas de bárions, são compostas por quarks de carga de cor diferente (vermelho, verde e azul) e partículas contendo dois quarks, chamadas de mésons, são compostas de um par de quarks contendo cor e anticor. A Tabela 2.3 sumariza as interações descritas pelo Modelo Padrão juntamente com suas partículas mediadoras.

Tabela 2.3: Partículas mediadoras das forças forte, fraca e eletromagnética, juntamente com suas massas e o ano de descoberta

Força	Mediador	Massa	Data da Descoberta
Eletromagnética	γ	$< 10^{-18}$ eV	1900 [30, 31]
Fraca	W^\pm, Z^0	$80,385 \pm 0,015$ GeV $91,188 \pm 0,002$ GeV	1983 [32–35]
Forte	8 glúons	0	1979 [36]

2.3 O Grande Colisor de Hádrons (LHC)

O LHC[37], o maior e mais poderoso acelerador de partículas do mundo, começou a sua operação no dia 10 de setembro de 2008 [38], e continua sendo a última adição ao complexo de aceleradores do CERN. Dentro do acelerador, a 100 metros abaixo da superfície, em um túnel de 27 km situado nos arredores de Genebra, na fronteira franco-suíça, dois feixes de partículas altamente energéticas viajam próximos da velocidade da luz³, antes de colidirem um com o outro.

Em tubos separados, os feixes percorrem o acelerador em direções opostas até o momento de sua colisão. Para que haja o mínimo de interferência possível, os tubos por onde os feixes circulam precisam estar livres de outras partículas, logo

³Cada feixe de partículas completa mais de 11 mil voltas por segundo no acelerador.

faz-se necessário obter um ambiente próximo ao vácuo absoluto. Com a pressão atmosférica dos tubos na ordem de 10^{-11} mbar e uma temperatura de 1,9 K, o vácuo nos tubos do LHC é quase tão rarefeito quanto o presente na superfície lunar. Além disso, essas temperaturas tão baixas permitem explorar a supercondutividade de alguns materiais.

Com isso, os feixes são guiados ao redor do acelerador por um campo magnético mantido por eletroímãs supercondutores, conduzindo eficientemente eletricidade com menor resistência ou perda de energia. Por esta razão, grande parte do acelerador é conectado a um sistema de distribuição de hélio líquido, que resfria os ímãs, bem como a outros serviços de fornecimento [39].

No LHC, feixes de prótons, ou íons pesados, colidem em quatro pontos de interação, onde os principais experimentos estão localizados. São eles: o ATLAS (*A Toroidal LHC ApparatuS*)[40] e CMS (*Compact Muon Solenoid*)[41], que são detectores de propósito geral; ou seja, estudam toda a física envolvida nas colisões próton-próton, o experimento ALICE (*A Large Ion Collider Experiment*)[42], desenvolvido para estudar o produto das colisões de íons pesados, e o LHCb (*Large Hadron Collider Beauty Experiment*)[43], especializado na física do quark b .

A Figura 2.1 mostra uma visão esquemática do complexo de aceleradores do CERN. Os prótons passam por diversos pré-aceleradores antes de chegarem ao LHC. Dipolos e quadrupolos geram campos magnéticos, que excedem 8 T, responsáveis por manter os feixes dentro da órbita circular do acelerador, enquanto cavidades de rádio-frequência são usadas para o processo de aceleração destes feixes [44]. Um recipiente com gás hidrogênio é usado como fonte de prótons da seguinte maneira: elétrons são retirados dos átomos de hidrogênio com o auxílio de um campo elétrico, assim os prótons restantes dos átomos são levados ao acelerador linear (LINAC 2), responsável por aumentar suas energias para 50 MeV antes de injetá-los no *Booster*, onde atingirão uma energia de 1,4 GeV. Em seguida, os prótons passam para o *Proton Synchrotron* (PS), onde são acelerados a 25 GeV, e, em seguida, passam para o *Super Proton Synchrotron* (SPS), que finalmente injeta os prótons no LHC, com uma energia de 450 GeV, onde são acelerados até a energia necessária para a colisão.

Devido ao LHC representar a vanguarda das tentativas de entender a natureza fundamental do Universo, estamos vivendo uma época notável para a cosmologia, astrofísica e física de partículas. A descoberta do bóson de Higgs em 2012 foi, sem dúvida, um marco importante na história da física. Além disso, o LHC possui potencial para ajudar a responder outras questões fundamentais da nossa época: a existência ou não de supersimetria, a verdadeira natureza da matéria escura e a existência de dimensões extras. O LHC permanecerá o maior e mais poderoso acelerador de partículas do mundo por, pelo menos, mais duas décadas. Sua completa exploração é a maior prioridade da comunidade científica de física de altas energias.

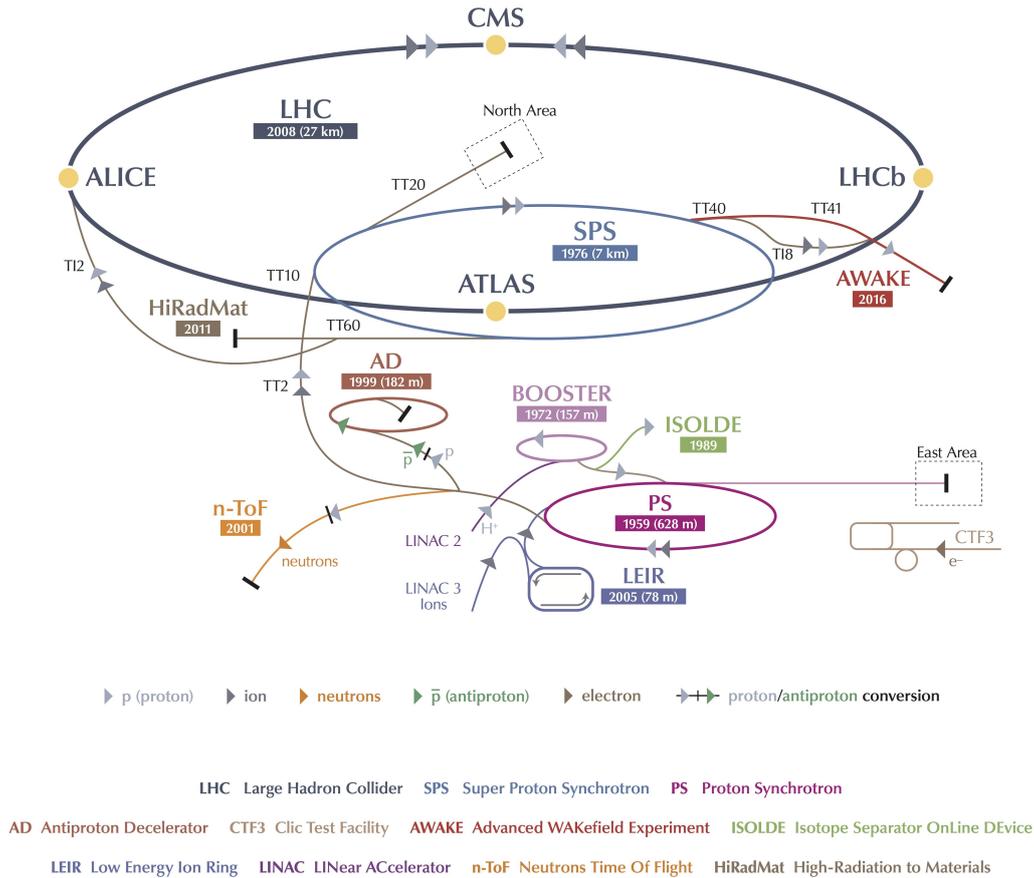


Figura 2.1: Complexo de aceleradores do CERN. Extraído de [45].

2.4 O Experimento ATLAS

O detector ATLAS [40] é o maior experimento de física de altas energias presente no LHC. Com uma colaboração composta por 3000 autores de mais de 180 instituições de ensino ao redor do mundo, o ATLAS também se torna uma das maiores colaborações científicas já criadas pela humanidade. Além dos 1200 estudantes envolvidos em tarefas como desenvolvimento de detectores, aquisição e análise de dados, a colaboração também conta com o esforço de inúmeros engenheiros, técnicos e pessoal administrativo.

O detector foi pensado para estudar o extenso programa de física do LHC, desde a busca pelo Bóson de Higgs até a procura por dimensões extras e partículas candidatas à matéria escura. Como a maioria dos detectores de propósito geral, o ATLAS possui um formato cilíndrico cobrindo um ângulo sólido de aproximadamente 4π ao redor do ponto de colisão, desta forma o detector é capaz de registrar as partículas produzidas em todas as direções. A Figura 2.2 mostra uma visão geral do detector, destacando suas grandes dimensões. O ATLAS possui 44 m de comprimento, 25 m de diâmetro e pesa aproximadamente 7000 kg.

Para realizar medidas de trajetória e energia com alta precisão o ATLAS conta

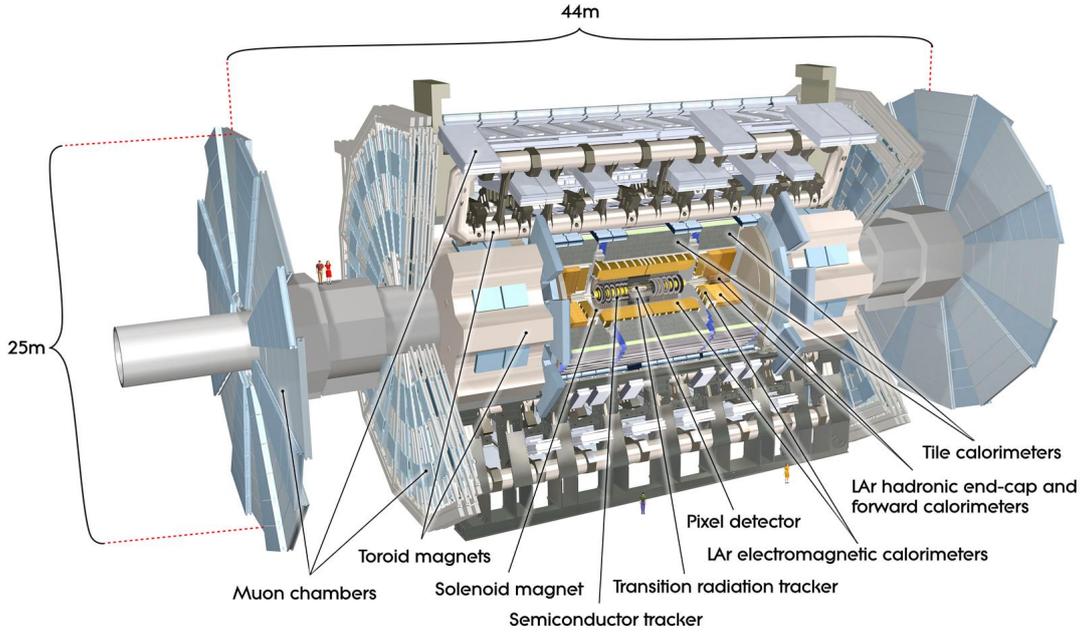


Figura 2.2: Visão esquemática do detector ATLAS. Extraído de [40].

com um sistema de subdetectores que possuem características e funcionalidade diferentes. São eles:

- Detector Interno (*Inner Detector* - ID): Composto por um conjunto de detectores de traços, o ID é posto ao redor de ponto de colisão e foi projetado para a reconstrução da trajetória de partículas carregadas [46].
- Sistema de Calorimetria: Abrange o Calorímetro de Argônio Líquido (*Liquid Argon* - ID) e o Calorímetro de Telhas (*Tile Calorimeter* - TileCal), ambos são responsáveis pela medida de energia de partículas eletromagnéticas e hadrônicas, respectivamente [47].
- Espectrômetro de Múons (*Muon Spectrometer*): Utiliza um complexo campo magnético toroidal para curvar a trajetória dos múons e medir seu momento [48].

Depois de um longo e intenso período de pesquisa e desenvolvimento, o ATLAS operou entre 2010 e 2012 e após um período de inatividade retornou às suas operações em 2015 com o fim da sua primeira fase de atualizações. Em Julho de 2012, através dos dados coletados tanto pelo ATLAS [49] quanto pelo experimento CMS [50], a colaboração anunciou resultados que comprovavam a existência de uma partícula compatível com o Bóson de Higgs que culminou com a entrega do Prêmio Nobel de Física no ano seguinte para François Englert e para Peter Higgs por seus trabalhos teóricos propostos separadamente em 1964.

2.4.1 Sistema de Coordenadas

Uma descrição consistente das regiões do detector exige a definição de um sistema de coordenadas, que é introduzido a seguir e usado ao longo deste trabalho. O ATLAS possui seu sistema de coordenadas com origem no seu ponto de interação, onde ocorrem as colisões, e seu eixo z ao longo do feixe. O eixo x aponta do ponto de interação até o centro da circunferência do LHC e o eixo y aponta verticalmente para cima, criando, assim o plano $x - y$ transverso à linha do feixe. Coordenadas cilíndricas (r, ϕ) são usadas no plano transverso, onde ϕ é o ângulo azimutal ao redor do eixo do feixe e o ângulo polar θ é medido a partir da linha do feixe e relativo ao eixo z positivo. O sistema de coordenadas pode ser visualizado na Figura 2.3.

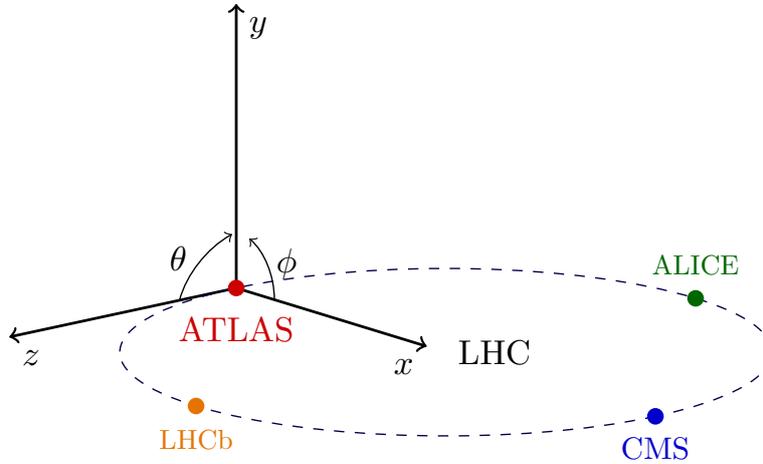


Figura 2.3: Sistema de coordenadas do ATLAS.

Em física de partículas, o ângulo polar pode ser convenientemente expresso através da pseudo-rapidez, η , uma coordenada espacial utilizada para descrever o ângulo da partícula em relação ao feixe, definida como

$$\eta = -\ln \left[\tan \left(\frac{\theta}{2} \right) \right], \quad (2.3)$$

sendo θ o ângulo polar (entre a direção do movimento da partícula e a linha do feixe).

Utiliza-se a pseudo-rapidez, ao invés do ângulo polar, pois sua diferença entre duas partículas é um invariante de Lorentz [51] sobre o eixo longitudinal; ou seja, não dependem do sistema de referência. Por isso, os limites da segmentação do calorímetro do ATLAS são definidos por intervalos de pseudo-rapidez.

Grandezas físicas medidas no plano transverso $x - y$ são muito utilizadas em física de partículas, como por exemplo o momento transversal que é calculado em função do ângulo polar da partícula através da equação

$$p_T = p \times \sin \theta. \quad (2.4)$$

2.5 O Calorímetro Hadrônico de Telhas

Em experimentos de física de altas energias, os calorímetros hadrônicos são parte fundamental na medição da energia e direção de objetos físicos conhecidos como jatos de partículas (Capítulo 4). Além disso, os calorímetros também podem fornecer informação extra para o sistema de filtragem de eventos [52] e participar da medida de energia transversa perdida (*missing transverse energy*) na detecção de partículas que não interagem com o detector [53].

Cobrindo a porção central do detector ATLAS, se encontra o Calorímetro de Telhas (*Tile Calorimeter* - TileCal). Seu volume é composto em quatro partições ao longo do eixo do feixe de partículas (eixo z). Temos dois barris centrais chamados de *Long Barrels*, LBA e LBC, e dois barris estendidos, chamados de EBA e EBC mostrados na Figura 2.4.

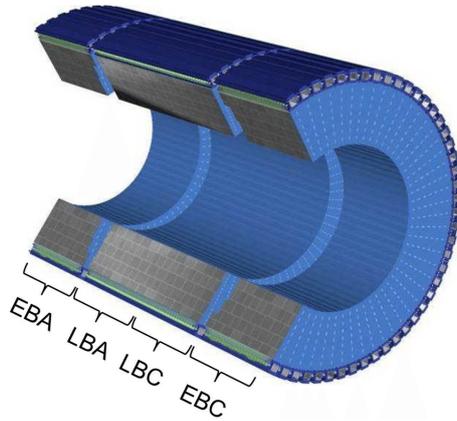


Figura 2.4: Módulos do TileCal. Extraído de [40].

Ao todo o TileCal consiste em 64 módulos dispostos ao redor do feixe, cada um cobrindo um ângulo azimutal de $\Delta\phi = 0.1$ e uma pseudo-rapidez de $|\eta| < 1.7$. O TileCal é constituído de materiais absorvedores e cintiladores intercalados entre si. Quando uma partícula carregada passa pelo material cintilante, uma luz ultravioleta é emitida e transportada até um aparato responsável por converter o sinal luminoso em um pulso elétrico de amplitude proporcional à energia da partícula depositada. Todo este processo da cadeia de leitura é detalhado no Capítulo 3.

Capítulo 3

Calorimetria no TileCal

Experimentos modernos no campo de Física de Partículas necessitam cada vez mais dos processos de Calorimetria [54]. A calorimetria trata-se de uma técnica de detecção na qual as partículas de interesse são completamente absorvidas pelo detector, constituindo um processo destrutivo. Nos experimentos atuais, os grandes sistemas de calorímetros, como são chamados os detectores que usam os procedimentos de calorimetria, desempenham um papel central, e espera-se que esse cenário não se altere nos experimentos que estão sendo planejados para o futuro [55].

Neles, o detector fornece um sinal que representa a medida de energia depositada no processo de absorção completa da partícula. Em calorímetros *homogêneos*, todo o volume do detector contribui para a detecção do sinal; enquanto nos calorímetros de *amostragem*, a função de absorção da partícula e produção do sinal, são exercidas por diferentes materiais chamados de meio passivo e ativo, respectivamente. A grande maioria dos calorímetros que operam em experimentos de colisão, como é o caso do LHC, são calorímetros de amostragem.

Para obtermos medidas precisas das partículas que são depositadas no calorímetro, este deve possuir sua estrutura mecânica construída de maneira segmentada. Em um calorímetro finamente segmentado, podemos medir não apenas a energia cinética das partículas absorvidas pelo seu material, mas também somos capazes de reconstruir propriedades de seu quadrivetor¹, incluindo massa e tipo da partícula detectada. Em outras palavras, com uma alta granularidade é possível obter medidas precisas da posição de interação da partícula com o detector.

3.1 Cadeia de Leitura

O calorímetro hadrônico do ATLAS (*Tile Calorimeter* - TileCal) [56] é um calorímetro de amostragem que utiliza telhas de material cintilante como material ativo,

¹Vetor quadridimensional, utilizado na teoria da relatividade, que possui as três coordenadas espaciais (x, y, z) e a coordenada temporal (t).

intercalado com placas de aço como material absorvedor. Os hádrons que entram no calorímetro interagem com o núcleo do material absorvedor, produzindo uma cascata de novas partículas neutras e carregadas.

Fibras WLS (*Wavelength Shifting Fibers*) [57] fazem o transporte do sinal luminoso, gerado nas telhas, até os tubos fotomultiplicadores (*Photomultiplier Tube* - PMT), que são responsáveis por transformar este sinal em um pulso elétrico com amplitude diretamente proporcional à energia da partícula depositada no calorímetro. Estas fibras estão acopladas aos dois lados de cada telha, que, por sua vez, são conectadas a duas PMTs que realizam a leitura da mesma célula. Esta configuração foi pensada para obter uma uniformidade do sinal coletado. O esquema mostrado na Figura 3.1 permite uma visualização do sistema descrito acima.

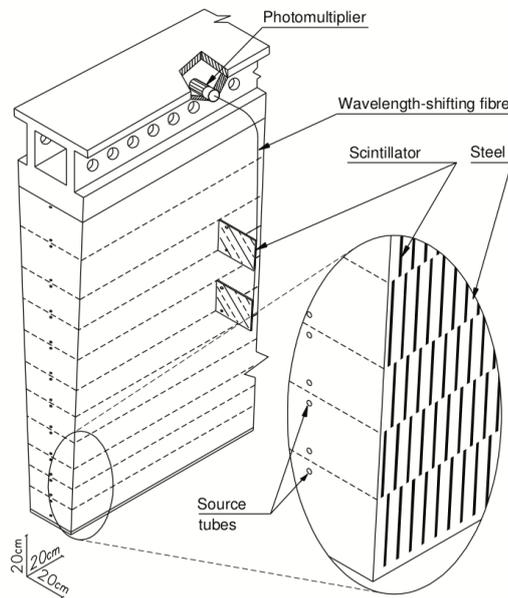


Figura 3.1: Visão esquemática de um dos 64 módulos do TileCal. A figura mostra os materiais absorvedores e cintiladores intercalados entre si, bem como a fibra WLS que vai da telha cintiladora até o tubo fotomultiplicador no final do módulo. Extraído de [58].

3.2 Reconstrução do Sinal

De forma a realizar a reconstrução do sinal proveniente da passagem de uma partícula pelo calorímetro, primeiramente, o pulso gerado na saída da PMT é condicionado por um circuito de conformação (*shaper*) [59]. Com isso, todos os pulsos possuirão a mesma largura a meia altura, dentro de uma janela de 50 ns, fazendo, assim, o depósito de energia ser proporcional à amplitude do pulso. Em seguida, o pulso conformado é amplificado separadamente por amplificadores de alto ganho (*High Gain* - HG) e de baixo ganho (*Low Gain* - LG) em uma razão de 64 : 1,

com a finalidade de cobrir toda a faixa de energia requerida. Estes sinais, de alto e baixo ganho, são amostrados com uma frequência de 40 MHz e, em caso de uma decisão positiva do sistema de *trigger*, sete amostras, de um dos ganhos, são lidas e transferidas através de fibras WLS para os *Read Out Drivers* (RODs), localizados fora do detector, onde a estimação de energia é feita. Um exemplo de pulso gerado no TileCal pode ser visto na Figura 3.2.

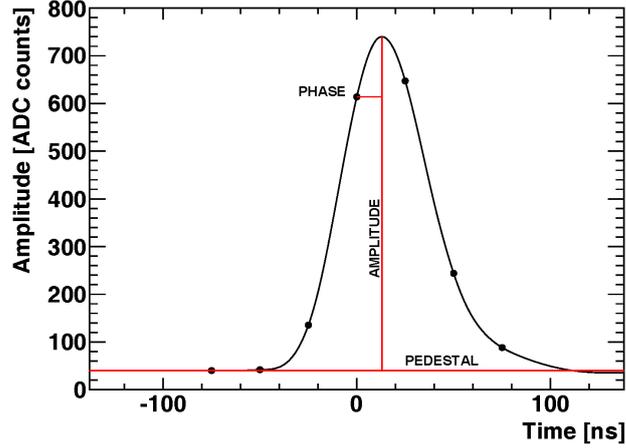


Figura 3.2: Exemplo de pulso formado no TileCal com suas sete amostras. Pedestal, amplitude e fase também podem ser vistos na figura. Extraída de [60].

A amplitude do pulso, para cada PMT, é derivada através do método chamado *Optimal Filtering* (OF) [61] que se baseia em uma soma ponderada das sete amostras recebidas. Assim a amplitude do pulso, A , é dada pela equação

$$A = \sum_{i=0}^{n=7} a_i S_i, \quad (3.1)$$

onde S_i é a amostra no tempo t_i ($i = 1, \dots, n$) e os coeficientes a_i são derivados pelo OF a partir do pulso de referência e da matriz de covariância do ruído para cada canal [62]. Toda a formulação do OF tem como objetivo minimizar a variância da distribuição de amplitude. Vale ressaltar que devido à simplicidade de implementação do algoritmo OF, ele também pode ser utilizado em análises *online*, através de uma implementação em *hardware*.

3.3 Segmentação do Calorímetro

Dividido em um barril central (*Long Barrel* - LB) e dois barris estendidos (*Extended Barrel* - EB), o TileCal cobre a região de pseudo-rapidez $|\eta| < 1.7$ e é segmentado em 64 módulos ao redor do ângulo azimutal ϕ , cobrindo um ângulo de $2\pi/64 = 0.1$ graus em cada módulo. Cada PMT recebe o sinal de diversas telhas, que são agrupadas em

células de diferentes tamanhos, dependendo da sua profundidade e pseudo-rapidez. Três camadas de células são definidas e as suas dimensões são otimizadas de forma a obter uma estrutura de torre, como mostra a Figura 3.3. Ao todo 5184 células são lidas, através de canais duplos ou simples, em um total de 9856 canais que correspondem a uma segmentação $\Delta\eta \times \Delta\phi = 0.1 \times 0.1$, nas duas primeiras camadas, e 0.2×0.1 na última camada.

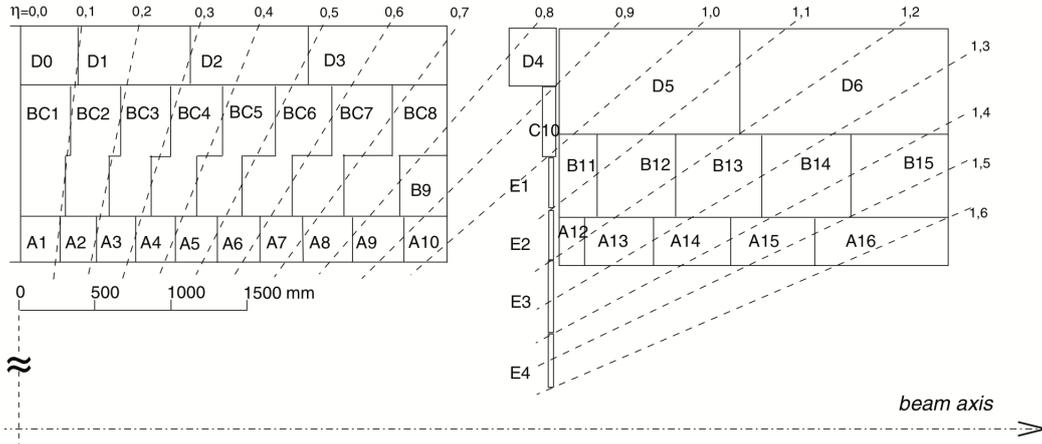


Figura 3.3: Módulos central e estendido do TileCal. A segmentação do calorímetro é ditada pelo tamanho de cada uma de suas células. Extraído de [63].

As telhas cintiladoras estão organizadas em 11 fileiras de tamanhos diferentes e numeradas a partir do menor raio. Ou seja, a fileira de número 1 está mais próxima do feixe e a fileira de número 11 é a mais distante do feixe. As células denominadas pela letra A correspondem às fileiras de telhas 1, 2 e 3, enquanto que, as células de letra B possuem as fileiras 4, 5 e 6, as células C englobam as fileiras 7, 8 e 9, e, finalmente, as células D possuem as duas últimas fileiras 10 e 11. A Figura 3.4 mostra um módulo do barril estendido, atualmente usado para calibração e testes de estabilidade, com toda a sua instrumentação ótica e eletrônica.

3.4 Conjunto de Fibras

O processo de juntar todas as fibras, pertencentes a uma dada célula, em um único aglomerado (*fiber bundle*) é mostrado na Figura 3.5. Um misturador de luz (*light mixer*) é responsável por combinar o sinal luminoso de cada uma das fibras em um único feixe de luz, de forma a otimizar a uniformidade do sinal [65]. Os misturadores de luz utilizam as múltiplas reflexões internas, de forma a tornar mais aleatório o impacto da luz no fotocátodo da PMT. Assim, a resposta individual de cada fibra não depende de sua posição dentro do conjunto. O misturador de luz também evita variações sistemáticas devido às não-uniformidades na eficiência do fotocátodo. A Tabela 3.1 sumariza o número de fibras em cada uma das células do TileCal.

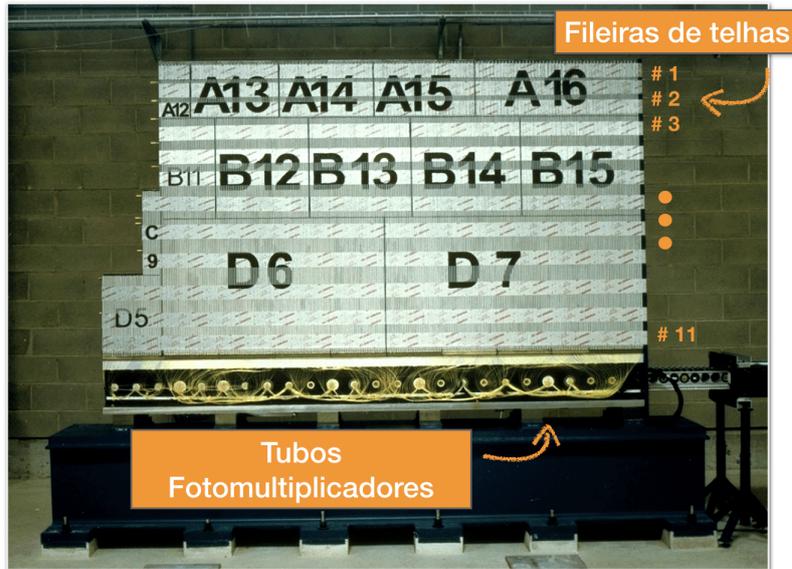


Figura 3.4: Módulo do barril estendido. Na figura pode-se observar a divisão espacial de cada célula, os tubos fotomultiplicadores acoplados ao final do módulo e cada uma das suas onze fileiras de telhas. Extraído de [64].

No barril central (LB), as sub-células B e C são lidas pela mesma PMT. Desta forma, as cascatas de partículas hadrônicas são amostradas, no TileCal, em três camadas de profundidade no sentido radial do detector. Em outras palavras, para o barril central temos a leitura das células A, BC e D. Cada módulo do barril central possui 307 telhas por fileira, totalizando 3377 telhas; já no barril estendido, existem entre 140 e 157 telhas por fileira, com um total de 1591 telhas cintiladoras.



Figura 3.5: Aglomerado de fibras acoplado ao seu misturador de luz. Extraído de [58].

Tabela 3.1: Número de fibras em cada uma das células do TileCal.

	Célula	Número de Fibras
Barril Central	A1-A10	27-37
	BC1-BC6	65-77
	BC7-BC8, D0-D3	80-100
Barril Estendido	A12, C10, E1-E4	6-18
	B11, D4	32-34
	A13-A15, B12-B15	50-70
	A16	96
	D5-D6	130-150

3.5 Sistema de Calibração

Como o sinal coletado por cada fotomultiplicadora é convertido em energia para as análises físicas, esta relação deve ser calculada com bastante atenção. Para isso, o TileCal conta com um sistema de calibração utilizado para monitorar a estabilidade e performance de toda a sua cadeia de leitura durante o período de aquisição de dados no LHC [59]. O sistema de calibração possui diferentes sub-sistemas que, quando são combinados, fornecem informação para ajustar a resposta do calorímetro em cada um dos estágios descritos anteriormente, desde a luz emitida pelas placas cintiladoras até a digitalização do sinal. As constantes de calibração são usadas para converter o sinal digital, medido por contagens de ADC, em energia. Assim cada canal tem sua reconstrução de energia, $E(\text{GeV})$, dada pela seguinte equação:

$$E(\text{GeV}) = A(\text{ADC}) \times C_{\text{ADC} \rightarrow \text{pC}} \times C_{\text{pC} \rightarrow \text{GeV}} \times C_{\text{Cesium}} \times C_{\text{Laser}}, \quad (3.2)$$

onde $A(\text{ADC})$ é a resposta digitalizado do sinal, $C_{\text{ADC} \rightarrow \text{pC}}$ é a constante de conversão de ADC para pC, $C_{\text{pC} \rightarrow \text{GeV}}$ é a relação entre a resposta do detector, em pC, e o depósito de energia, em GeV, e, finalmente, C_{Cesium} e C_{Laser} são usadas para manter fixa a escala de energia. Apenas a constante $C_{\text{pC} \rightarrow \text{GeV}}$ é mantida fixa, todas as outras constantes são fornecidas através dos sub-sistemas descritos a seguir e visualizados na Figura 3.6.

3.5.1 Sistema de Césio

Sistema de Césio [67] consiste em uma fonte radioativa de Césio-137, que se move por todo o calorímetro, através de um sistema hidráulico, com o objetivo de calibrar as componentes óticas do TileCal. Também pode ser usada para avaliar a qualidade de toda a cadeia de leitura (cintiladores, fibras, fotomultiplicadoras e eletrônica).

Cada fonte de Césio emite fótons de 0.662MeV para iluminar as telhas cintilado-

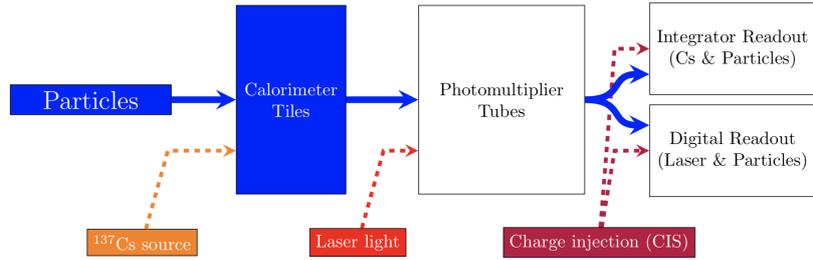


Figura 3.6: Diagrama dos diferentes sub-sistemas de calibração presentes no TileCal. Extraído de [66].

ras presentes nas células. A resposta da energia depositada em cada canal é usada para equalizar a resposta de todas as células, mantendo a resposta da escala global do calorímetro. Caso a medida do sinal de Césio sofra um desvio do seu valor esperado, a diferença desse valor é convertida em uma constante de calibração, como visto na Equação 3.2. A Figura 3.7 mostra os desvios da constante de calibração de Césio durante o Run II, anos 2015 e 2018, para diferentes camadas do calorímetro.

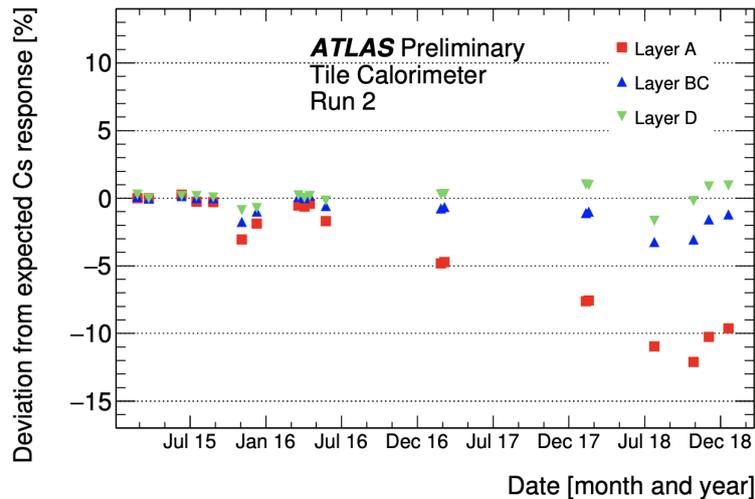


Figura 3.7: Variação da resposta do sistema de calibração de Césio do TileCal durante o Run II. Extraído de [68].

Podemos ver que a maior variação acontece para as células da camada A, pois estão mais próximas ao ponto de colisão do feixe. A precisão do sistema opera na ordem de 0.3% para uma célula típica. A frequência com que as calibrações de Césio são executadas diminui com o tempo. Durante 2015 o espaçamento era feito entre um e três meses, em 2016 a frequência dos *runs* de calibração foi reduzida, e eles passaram a ser executados apenas no início e no fim de cada período de colisão do LHC, sendo insuficientes para rastrear todas as variações na resposta das PMTs. Nesse sentido, a calibração via Laser é usada entre dois scans de Césio para corrigir

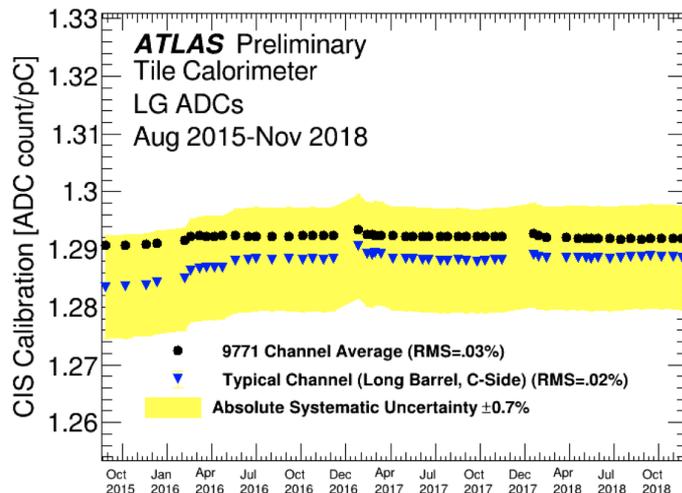


Figura 3.9: Médias das constantes de calibração CIS para todos os canais durante o Run II. Extraído de [70].

3.6 Atualização Para a Nova Luminosidade

O Calorímetro de Telhas é resultado de um longo processo de pesquisa e desenvolvimento, que começou com estudos de simulação (1993-1995), e teve seu Relatório Técnico (*Technical Design Report* - TDR) completado em 1995 [71], seguido de sua construção em 1996-2004. A instalação do calorímetro ocorreu em 2004-2006, acompanhada de seu comissionamento em 2007-2009, usando partículas produzidas por raios cósmicos [72]. Um longo caminho foi percorrido para o detector estar concluído para as colisões próton-próton ocorridas no LHC em 2009-2012 [73, 74].

Para ampliar o seu potencial de descoberta, o LHC passou por uma grande atualização de forma a aumentar sua luminosidade, que representa a taxa de colisões por unidade de área. Atualmente, o limite superior de luminosidade no LHC é de $L = 10^{34} \text{ cm}^{-2}\text{s}^{-1}$. Com a nova atualização pretende-se atingir uma luminosidade 5 vezes maior que a atual e, assim, possibilitar que os experimentos ampliem a sua quantidade de dados em comparação com o programa atual. Por conta da extrema complexidade do LHC, uma atualização desta magnitude deve ser cuidadosamente estudada. Os desenvolvimentos necessários exigirão cerca de 10 anos para serem prototipados, testados e postos em prática. Esta nova configuração será chamada de HL-LHC (*High Luminosity LHC*) e dependerá de um grande número de desafios tecnológicos [75].

O cronograma do projeto é ditado pelo fato de que, no início da próxima década, muitas componentes importantes do acelerador estarão no final da sua vida útil devido aos danos sofridos pela radiação e, portanto, precisarão ser substituídas. Desse modo, a nova atualização é crucial não apenas para a completa exploração do potencial do LHC, como também para permitir a operação do colisor para além

de 2027. Um plano de operação do LHC para os próximos anos pode ser visto na Figura 3.10, onde podemos ver que as atualizações sempre ocorrem quando o acelerador encontra-se desligado.

Os objetivos determinantes do comitê responsável pelo cronograma do HL-LHC são a instalação do *hardware* principal e o comissionamento da nova configuração do acelerador durante o terceiro grande desligamento (*third long shutdown*), programado para 2025-2027, enquanto tomam todas as providências necessárias para garantir a alta eficiência de operação para além de 2027.

O Capítulo 4 descreve os objetos físicos conhecidos como jatos de partículas, bem como sua importância na física de altas energias, como são simulados e reconstruídos no detector, e suas particularidades no novo ambiente do *High Luminosity* LHC.

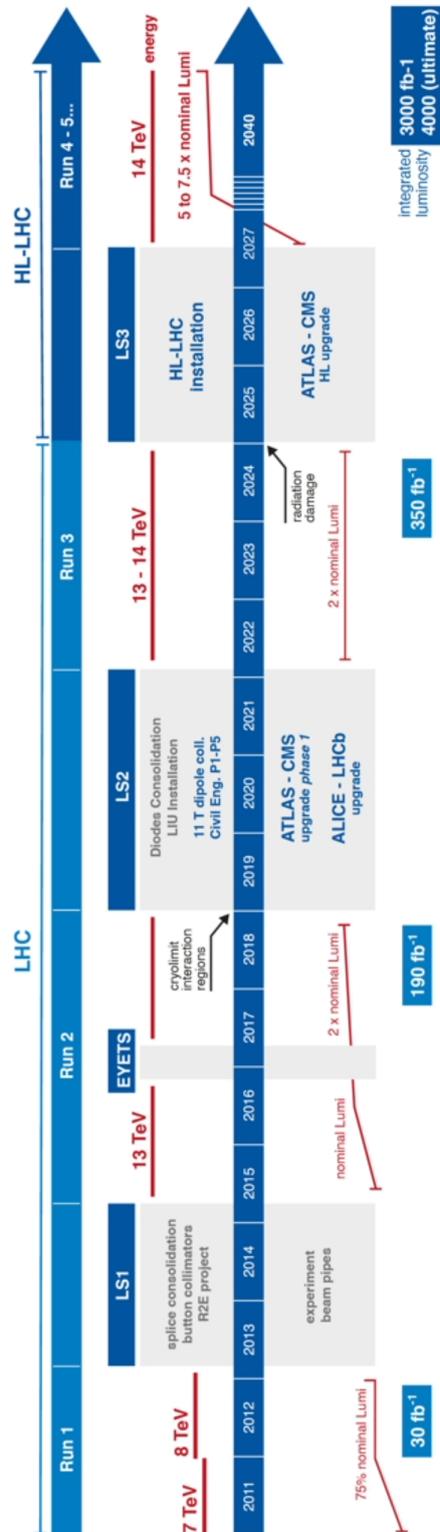


Figura 3.10: Plano base para a operação do LHC pelos próximos 20 anos. Após o terceiro grande desligamento (*long shutdown*), o acelerador entrará na nova configuração chamada HL-LHC. Extraído de [76].

Capítulo 4

Física de Jatos de Partículas

Sabemos que prótons e neutrons são compostos por partículas chamadas quarks, que estão ligadas entre si por outras partículas chamadas glúons. Assim como o fóton e o elétron, os quarks e glúons são considerados partículas elementares, ou seja, não possuem estrutura interna. Por outro lado, ao contrário do fóton e do elétron, os quarks e glúons não podem ser observados isoladamente. O motivo, possui respaldo na Cromodinâmica Quântica (*Quantum Chromodynamics* - QCD), que proíbe que partículas com carga de cor existam livremente na natureza, apenas permitindo combinações de partículas cujas cargas de cor se anulem, formando uma nova partícula com carga de cor nula (*colorless*), como foi descrito na seção 2.2; este fenômeno é conhecido como *confinamento* [77].

Por conta disso, quando um quark é criado em uma colisão, imediatamente acontece um processo chamado de hadronização, que consiste na criação de um hádron, partícula sem cor composta por quarks, através da criação de novos quarks e glúons que também sofrem hadronização. Este processo continua até a formação de um *spray* de hádrons, colimados em um formato de cone, que os físicos de partículas chamam de *jatos*.

Podemos dizer que jatos de partículas são as assinaturas de quarks e glúons produzidos em colisões de altas energias. Como não somos capazes de detectar partículas com carga de cor não-nula livremente na natureza, usamos os jatos como suas manifestações, de forma a entender melhor as partículas que o originaram. Por exemplo, podemos medir a energia total no cone que contém o jato e afirmar que este valor deve ser o mesmo valor de energia do quark inicial que o produziu. Além disso, combinações de jatos são produtos de decaimento de diversas partículas pesadas como, por exemplo, o quark top [78], os bósons W^\pm e Z^0 [79] e o próprio bóson de Higgs [80]. Com isso, o estudo das propriedades dos jatos são de suma importância para diversos processos físicos que ocorrem no LHC [81].

4.1 Simulações de Monte Carlo para Jatos de Partículas

Métodos de Monte Carlo são todos e quaisquer procedimentos que se iniciam com amostras aleatórias, para obter resultados numéricos. São extensamente utilizados em análise numérica e em simulações de fenômenos naturais. No contexto de Física de Partículas, os métodos de Monte Carlo são utilizados para produzir simulações teóricas de processos reais que ocorrem durante uma colisão de partículas; como, por exemplo, a cascata de partículas produzidas durante o processo de hadronização de um quark.

No entanto, qualquer grandeza física medida pelo detector, é afetada por suas imperfeições, como as não-linearidades presentes no aparato experimental em conjunto com regiões de baixa resolução no detector. Assim, as simulações dos processos físicos que ocorrem no ATLAS podem ser descritos em duas etapas:

- **Geração de eventos:** Modelos teóricos e fenomenológicos são usados para simular os processos físicos resultantes das colisões próton-próton do LHC. Essas simulações possuem os eventos verdadeiros, ou *particle-level jets*¹ como são chamados pela colaboração; pois tratam-se de simulações geradas de acordo com as regras do Modelo Padrão, ou seja, retratam como essas partículas se manifestam na natureza, antes da interação com a matéria presente nos detectores. Usualmente, existe um gerador de Monte Carlo para cada processo diferente, pois em seu funcionamento utilizam-se informações como modelos de hadronização, distribuições de probabilidade e equações de evolução das cascatas hadrônicas. Os geradores mais utilizados para as simulações de jatos são o PYTHIA [82], HERWIG [83], ALPGEN [84] e POWHEG [85].
- **Interação com o Detector:** Os estados finais das partículas simuladas no item anterior, passam por uma nova simulação que, desta vez, reproduz a eletrônica da interação da partícula com a matéria do detector, ou seja, é realizada uma simulação completa de todo o sistema do ATLAS. Este processo é feito através de um *software* chamado GEANT4 [86] que inclui diversas funcionalidades que vão desde a simulação de traços no detector interno, até os processos que ocorrem nos calorímetros eletromagnético e hadrônico. Ao final deste processo temos jatos simulados a nível do detector, chamados de *detector-level jets*.

Com acesso a ambas as etapas de simulação, podemos quantificar o quão distante, estatisticamente, as simulações de eventos medidos pelo detector (*detector-level*)

¹Esses eventos também são chamados de *truth-level jets*.

estão dos eventos verdadeiros (*particle-level*), e, em seguida, derivar métodos de calibração com a finalidade de corrigir esta diferença.

4.2 Reconstrução de Jatos

Jatos depositam sua energia em diversas células do calorímetro hadrônico do ATLAS; portanto, algoritmos de *clusterização* são necessários para agrupar estas células e, em seguida, calcular toda a energia depositada pelas partículas que compõem o jato. Devido ao conhecimento prévio da geometria do calorímetro, algoritmos baseados em *clusters* topológicos (*topo-clusters*) são utilizados como base para a reconstrução e identificação de jatos [87]. Estes *clusters* são formados através das etapas:

- Busca-se uma célula semente com razão sinal-ruído acima de um determinado limiar (t_{seed}).
- Células vizinhas são adicionadas caso possuam uma razão sinal ruído acima de um novo limiar, ($t_{neighbour}$), obviamente menor que o da célula semente.
- O *cluster* topológico é finalizado quando um anel de células com razão sinal-ruído maior que 0 é adicionado como uma fronteira do *cluster*.
- O processo continua até que todas as células semente tenham se esgotado.

Como as células vizinhas podem estar em camadas adjacentes do calorímetro, os *topo-clusters* são objetos tridimensionais que se expandem pelo calorímetro sem seguir uma forma fixa.

Em seguida, os *topo-clusters* alimentam o algoritmo de reconstrução de jatos chamado anti- k_t [88]. Este algoritmo define uma distância, d_{ij} , entre dois objetos, partículas e *clusters* encontrados no calorímetro, e uma outra distância, d_{iB} , entre um destes objetos e o feixe do acelerador. Para cada evento, começando com um conjunto completo de *clusters*, os parâmetros de distância são definidos como:

$$d_{ij} = \min(k_{ti}^{-2}, k_{tj}^{-2}) \frac{\Delta_{ij}^2}{R^2} \quad (4.1)$$

e

$$d_{iB} = k_{ti}^{-2}. \quad (4.2)$$

Onde $\Delta_{ij}^2 = (y_i - y_j)^2 + (\phi_i - \phi_j)^2$, e os valores de k_{ti} , y_i e ϕ_i são, respectivamente, o momento transverso, a rapidez e o ângulo azimutal do objeto i . A constante R é chamada de parâmetros de raio e a colaboração ATLAS tem um valor fixo para este parâmetro de 0,4.

Após todas as distâncias serem calculadas, a distância de menor valor é selecionada, caso esta distância seja entre os objetos i e j , eles são combinados em um novo objeto, caso o menor valor seja a distância entre um objeto i e o feixe, então i é considerado um jato e deletado da lista de objetos. Todas as distâncias são recalculadas e o processo se repete até que não restem mais objetos, apenas jatos de partículas identificados em cada iteração do algoritmo. O formato escolhido para combinar cada objeto, leva o jato reconstruído a obter um formato de cone com raio igual a R . No ATLAS, a implementação da reconstrução de jatos é feita pelo *software* FASTJET [89].

Com isso, podemos perceber que a segmentação do Calorímetro, ou seja, sua granularidade e posição topográfica de suas células, possui papel fundamental na reconstrução desses objetos físicos de suma importância em diversos estudos da física de altas energias. Basicamente, a reconstrução dos jatos de partículas possui as seguintes etapas:

- Jatos de Partons: quarks e glúons antes da hadronização.
- Jatos de Partículas: estado final das partículas após a hadronização.
- Jatos Reconstruídos: objetos físicos medidos pela eletrônica do calorímetro.

A figura 4.1 mostra uma representação do processo de reconstrução de jatos dentro do TileCal, juntamente com um exemplo de como as células do detector podem ser agrupadas pelos algoritmos descritos nessa seção.

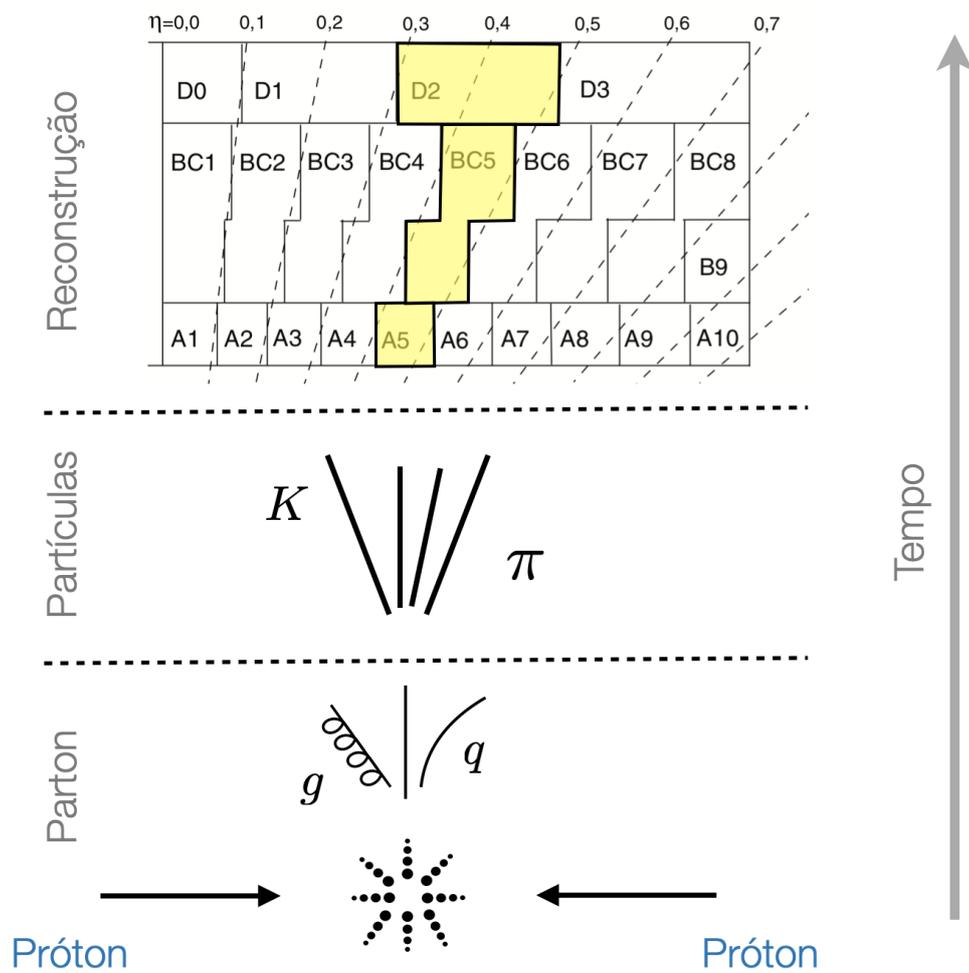


Figura 4.1: Visão pictórica da reconstrução de jatos de partículas no calorímetro de telhas do ATLAS (TileCal).

Capítulo 5

Nova Proposta de Segmentação

A segunda fase do *upgrade* do Calorímetro de Telhas [90] inclui uma reformulação completa de sua eletrônica, sem alterar as partes mecânica e ótica do detector. Contudo, existe uma possibilidade técnica de usar as informações individuais de cada telha cintiladora, que, quando agrupadas, formam o sinal presente em uma célula específica, e, desta forma, tornar mais fina a granularidade efetiva do calorímetro, sem modificar-lhe a parte mecânica.

Entende-se por granularidade mais fina o aumento da segmentação do detector na região de pseudo-rapidez, que pode ser obtido através da divisão das células originais do TileCal em novas regiões de η . No entanto, o aumento da segmentação na coordenada ϕ não será possível, uma vez que as partições de cada um dos 64 módulos, presentes no barril, são fixas.

Como foi explicado no capítulo 3, a luz emitida pelas telhas cintiladoras é levada à uma fotomultiplicadora através de fibras óticas agrupadas em um conjunto (*bundle*), que, por sua vez, estão acopladas à um misturador de luz. A ideia básica deste trabalho é buscar uma forma de tornar mais fina a granularidade do TileCal, empregando-se um tubo fotomultiplicador com capacidade de leitura multianodo (*Multi Anode Photomultiplier* - MA-PMT), com uma grade de 8×8 *pixels*, capaz de ler o sinal individual de cada uma das fibras do conjunto e, assim, obter informação adicional da distribuição de energia depositada numa célula.

A princípio, seria possível realizar o processamento analógico de cada um dos sinais associados às telhas cintiladoras. Porém, para limitar o número de canais na cadeia de leitura, as células originais podem ser divididas em novas sub-células através de uma soma digital dos sinais de cada fotossensor individual presente na nova MA-PMT, caso uma associação entre *pixels* e fibras possa ser feita corretamente.

O cenário ótimo é atingido caso as células A do barril central sejam divididas em 4 subcélulas na região de pseudo-rapidez (η). Isso significa atingir uma granularidade de 0,025 em η , quatro vezes mais fina que a original, a mesma segmentação presente na última camada do calorímetro eletromagnético. Além disso, a forma

em que as células BC estão agrupadas torna possível divisão desta camada intermediária, retomando a divisão nas camadas B e C, aumentando a segmentação radial do TileCal e proporcionando, aproximadamente, que todas as camadas do TileCal possuam a mesma espessura. Com isso, os efeitos do empilhamento de sinais¹ serão reduzidos e a performance global do TileCal será aprimorada.

5.1 Melhorias na Performance

Como discutido no capítulo 4, uma característica dominante das colisões altamente energéticas que acontecem no LHC é a produção de *sprays* de hádrons, colimados em um formato de cone, chamados de jatos [91]. Esta seção avalia a possibilidade de modificação na leitura do TileCal com o objetivo de melhorar a reconstrução de objetos físicos de alto momento transversal, como os jatos de partículas. Independente da implementação técnica das modificações necessárias para a nova granularidade, as provas de conceito foram geradas através de simulações com métodos de Monte Carlo [92], com a finalidade de ilustrar os benefícios destas modificações para performance física do ATLAS.

No TileCal, as telhas cintiladoras estão dispostas perpendicularmente ao eixo do feixe de colisão, formando diferentes camadas, que são ordenadas radialmente (Figura 3.3). Estes três segmentos possuem um comprimento de interação nuclear², que é definido como a distância média que uma partícula hadrônica percorre livremente entre duas interações inelásticas [93, 94], de $1,5 \lambda_I$ na camada A, $4,1 \lambda_I$ na camada BC e $1,8 \lambda_I$ na camada D do barril central; enquanto, no barril estendido os valores são de $1,5$, $2,6$, $3,3 \lambda_I$, respectivamente. Pode-se notar que a camada BC possui um comprimento maior, em comparação com as outras camadas A e D.

Dividir a camada BC está de acordo com propostas recentes em calorimetria hadrônica, onde buscam-se células menores que um comprimento de interação nuclear. Recentemente, este tipo de célula foi simulada dentro do ambiente de alta luminosidade do LHC (HL-LHC), mostrando que jatos de partículas com momento transversal da ordem de Tera elétron-Volts (TeV) possuem uma melhor reconstrução da sua subestrutura quando são detectados por calorímetros com granularidade mais fina [95]. Por outro lado, dividir a camada A em novas células, na região de pseudo-rapidez, fará com que cada subcélula reconstrua uma fração da cascata hadrônica, aumentando a informação no perfil transversal dos jatos.

Assim, temos duas possibilidades de tornar mais fina a granularidade do calorímetro. A primeira trata de dividir a célula BC e recuperar a concepção original do

¹Fenômeno que ocorre quando a resposta dos sensores é mais lenta do que a taxa de eventos. Ou seja, a janela de aquisição possui, além do seu sinal de interesse, outros sinais sobrepostos.

²Esta variável possui um valor diferente para cada partícula e detector, pois depende da densidade do material e da seção de choque da partícula.

calorímetro, onde temos duas células separadas, B e C; enquanto a outra possibilidade trata de dividir as células da camada A em duas novas células mantendo a simetria dos hemisférios direito e esquerdo da célula. Ou seja, uma opção de granularidade longitudinal para a camada BC e uma nova segmentação transversal para as células da camada A. Ambas possibilidades de segmentação são discutidas na a seguir.

5.1.1 Granularidade Longitudinal

O projeto original do TileCal possuía uma leitura separada para as células B e C; no entanto, estas camadas foram agrupadas durante a construção do detector, a fim de reduzir o custo com a cadeia de leitura. Assim, dividir a camada BC está totalmente alinhada com o projeto original. Como já foi citado na seção 1.1, a energia dos jatos de alto momento transversal tende a ser depositada em camadas mais profundas do TileCal. Para jatos com $p_T > 1,3$ TeV, em média, 50% da energia depositada no TileCal estará na camada BC [96]. Dividir a camada BC em duas camadas distintas ajudará na coleta de informação sobre o perfil longitudinal destes jatos. Atualmente, a falta de uma granularidade mais fina nesta camada pode, inclusive, limitar a possibilidade de encontrar novos tipos de física que dependem de medidas precisas de jatos com alto momento transversal, como, por exemplo, a busca por matéria escura, onde o TileCal desempenhará um papel crucial [97].

Um outro aspecto importante na divisão da camada BC é que a implementação atual da eletrônica de leitura possui um limiar máximo de energia que compreende a faixa de $1,2 - 1,5$ TeV. Como a deposição de energia na camada BC aumenta para jatos de alto p_T , esta limitação pode afetar em torno de 4% dos jatos provenientes do Modelo Padrão [98]. Desta forma, uma divisão nesta camada pode mitigar este problema, mesmo que a faixa dinâmica da eletrônica continue a mesma após o *upgrade*.

5.1.2 Granularidade Transversal

Como foi dito anteriormente, muitos processos estudados pelo programa de física do experimento ATLAS exigem uma medida precisa de jatos de partículas. Ao dividir a camada A em sub-regiões de η , aumentamos a precisão transversal na reconstrução de cascatas de partículas hadrônicas e, conseqüentemente, na reconstrução dos jatos.

Um exemplo de física além do Modelo Padrão, que pode ocorrer no LHC, é um processo de decaimento que produz novas partículas massivas com um *boost* em seu momento [99, 100]. Isto significa que, no sistema referencial do laboratório, nosso ponto de vista, as partículas provenientes do decaimento possuem a mesma direção de momento que a partícula que as produziu. Um exemplo disso é o decaimento do

Z' [101], uma partícula prevista por modelos além do Modelo Padrão e equivalente ao bóson Z , em um par de quarks top ($Z' \rightarrow t\bar{t}$). Em seguida, cada quark top decai em um bóson W e um quark b ($t \rightarrow Wb$). Geralmente, as reconstruções de energia e massa do quark top são feitas combinando-se o resultado de cada produto de seu decaimento. Porém, quando o quark top é produzido com um *boost* em seu momento, seus produtos são colimados em um único jato, sendo impossível distinguir cada um deles. Ou seja, as partículas provenientes do decaimento possuem tamanha energia cinética que, embora sejam objetos físicos diferentes, não há tempo suficiente para eles se separarem antes de serem registrados pelo detector. A Figura 5.1 ilustra esse cenário.

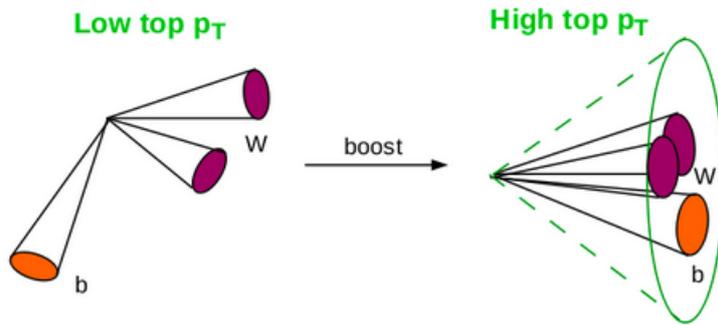


Figura 5.1: Colimação de partículas em um único jato por conta do *boost* de momento sofrido pela partícula original.

A distância entre duas partículas, no plano $\eta-\phi$, pode ser calculada pela equação:

$$\Delta R = \sqrt{(\Delta\eta)^2 - (\Delta\phi)^2}. \quad (5.1)$$

Para mostrar o efeito da colimação de partículas no decaimento citado anteriormente, a Figura 5.2 mostra a distância angular entre os dois quarks b , resultantes do Z' decaindo no par $t\bar{t}$, onde cada quark top decai em $t \rightarrow Wb$ em função do momento transversal do bóson W , p_T^W . Podemos ver que a separação entre os dois quarks se torna comparável com o tamanho atual das células presentes na camada A do calorímetro, 0.1 em ϕ e η , para $p_T^W > 600 \text{ GeV}$.

Com isso, fica claro que uma granularidade mais fina no calorímetro hadrônico do ATLAS é de suma importância para a análise de jatos com alto momento transversal. As melhorias nas medidas atingem posição, massa, momento, energia, além de outras características que refletem a estrutura interna dos jatos de partículas.

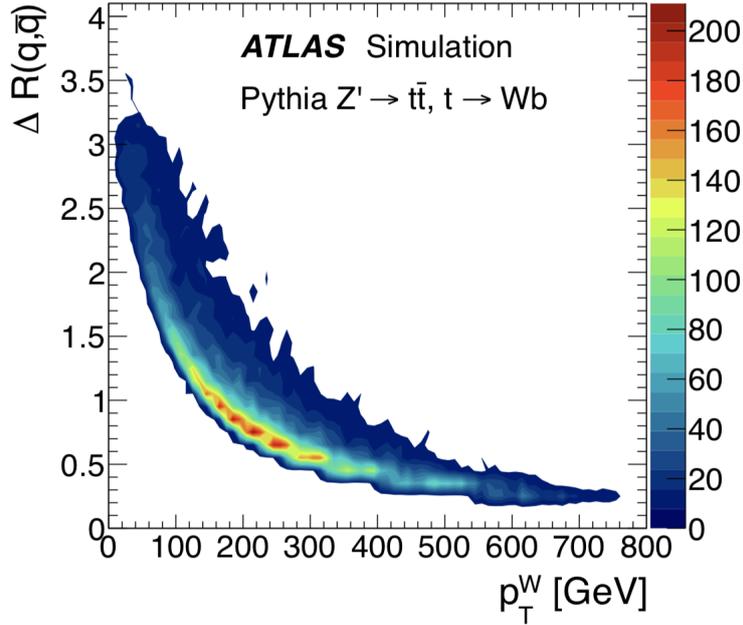


Figura 5.2: Separação angular entre os quarks produzidos no decaimento $Z' \rightarrow t\bar{t}$, onde cada quark top decai em $t \rightarrow Wb$ em função de p_T^W . Extraída de [101].

5.2 Simulações de Monte Carlo para Nova Granularidade

A discussão da seção 5.1 sobre a possibilidade de melhorias no programa de física do ATLAS após a divisão das camadas A e BC do calorímetro hadrônico devem ser confirmadas através de simulações de Monte Carlo. Estudos realizados fora do contexto do experimento ATLAS [102] podem ser considerados um cenário extremo ao proposto neste trabalho, uma vez que estes estudos foram baseados em simulações que incluem um total de 64 camadas longitudinais e uma segmentação uniforme de células nas direções de ϕ e η . Para o TileCal, estas simulações podem servir como um padrão, a ser seguido, nos estudos de granularidade, que, obviamente, será reduzido pelo fato da proposta atual envolver apenas uma melhora na granularidade para a direção de η na camada A e uma divisão da camada BC.

Um outro exemplo, trata das simulações realizadas para o novo ambiente de luminosidade HL-LHC. Objetos de alto momento transversal decaindo hadrônicamente em produtos colimados, como visto na Figura 5.1, apresentam uma dificuldade de reconstrução. Para solucionar este problema, os jatos são reconstruídos dentro de um cone maior que o normal, chamados de jatos com grande R (*large- R jets*) [103] por conta do raio que compõe seu cone ter um valor alto, $R = 1,0$, comparado com o raio usado em outros algoritmos, $R = 0,2 - 0,4$. Um exemplo é a produção de uma nova partícula massiva chamada W' , que pode decair em pares de bósons W e

Z que, conseqüentemente, decaem em jatos hadrônicos. Um processo similar ao da partícula Z' discutida na seção 5.1.2. Caso o bóson W' seja pesado o suficiente, seus produtos terão um *boost* de Lorentz e, assim, podem se beneficiar da reconstrução através de um cone maior. Neste contexto, o decaimento $W' \rightarrow WZ \rightarrow qqqq$ foi simulado com uma amostra de massa $m_{W'} = 5\text{TeV}$ nos cenários atual e de alta luminosidade (HL-LHC).

O estudo dos jatos de grande R é mostrado na Figura 5.3, que mostra a resolução de massa, definida como a largura a meia altura da distribuição de massa dos jatos contendo 68% dos eventos que possuem a mesma massa que os jatos previstos pelo modelo (*truth*) antes da reconstrução, para as colisões atuais, linha tracejada, e as colisões presentes no HL-LHC, linha inteira. A resolução de jatos com momento transversal entre 500 GeV e 1,6 TeV é aproximadamente 10 – 20% pior que a resolução atual para eventos detectados no barril central, $|\eta| < 0,8$, e, em média 18% pior para os jatos de momento transversal de até 1,0 TeV para jatos detectados no barril estendido, $0,8 < |\eta| < 1,7$.

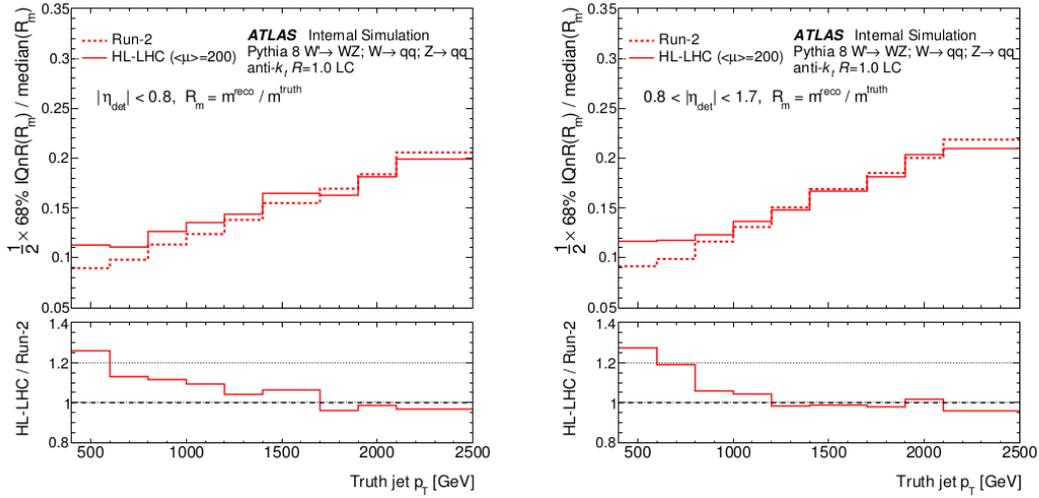


Figura 5.3: Resolução de jatos com grande R em função do momento transversal p_T^{jet} para o barril central, esquerda, e para o barril estendido, direita. Extraído de [104].

Novas simulações também foram feitas para atender às demandas da nova geometria proposta pelo TileCal. Esta geometria possui leituras separadas para as células B e C, já as células da camada A estão divididas em 4 subcélulas independentes em η , ou seja, com granularidade $\Delta\eta \times \Delta\phi = 0,025 \times 0,1$ nesta camada. Uma nova amostra de Monte Carlo foi usada para este estudo, com o mesmo decaimento do bóson W' discutido anteriormente. Ao comparar as variáveis relacionadas aos jatos de partículas entre as amostras de Monte Carlo, atual e após as modificações na geometria para upgrade, pode-se perceber a magnitude da melhora associada com a mudança de granularidade do TileCal. A Figura 5.4 mostra o número de elementos (*constituents*) associados aos jatos do decaimento do W' para as geometrias atual e

modificada, do barril central. Como esperado, o número de elementos internos dos jatos cresce para a nova geometria do calorímetro. Este resultado, também, justifica a busca por uma granularidade mais fina no TileCal.

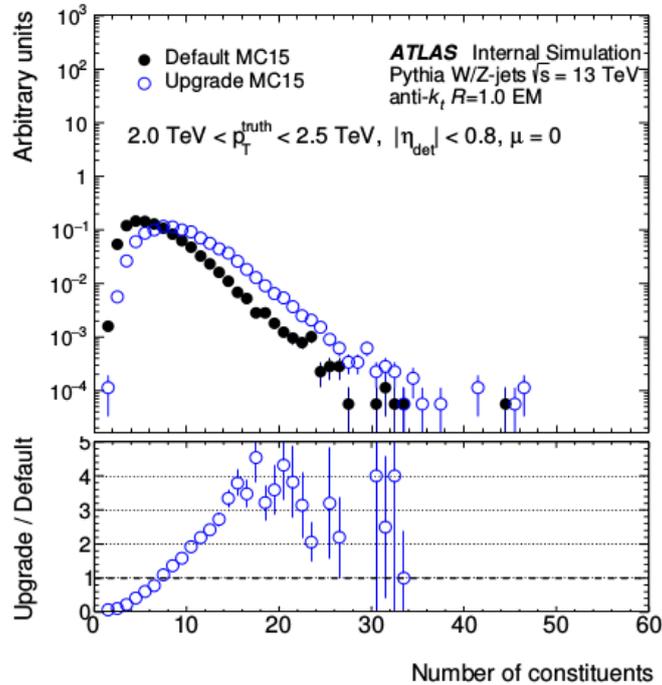


Figura 5.4: Número de elementos em grandes jatos, provenientes do decaimento do bóson W' para a geometria atual e modificada ($\Delta\eta \times \Delta\phi = 0,025 \times 0,1$).

5.3 Fotomultiplicadora Multianodal

As fotomultiplicadoras (PMT) são dispositivos construídos para gerar um pulso de corrente elétrica devido à incidência de fótons em seu fotocatodo. Em outras palavras, as PMT convertem um sinal luminoso em um pulso elétrico mensurável. Sua utilização não se limita apenas na física de partículas, há também aplicações em áreas como medicina [105, 106] e transmissão de dados por fibra ótica.

A estrutura básica de uma fotomultiplicadora consiste em um fotocatodo, que converte fótons em fotoelétrons, através do efeito fotoelétrico. Campos eletrostáticos direcionam os fotoelétrons em direção aos dinodos, dispostos progressivamente a potenciais mais altos, que funcionam como unidades multiplicadoras de elétrons. Ao chegar ao dinodo, cada elétron desloca em média 4 novos elétrons, que são acelerados até o próximo dinodo. Com isso, um ganho da ordem de 10^6 no número de elétrons é alcançado em uma fotomultiplicadora com 10 dinodos.

Ao final do processo, todos os elétrons secundários, produtos do primeiro fotoelétron, chegam ao anodo posicionado na outra extremidade do tubo fotomultiplicador.

Desta maneira, após a conversão de um fóton em vários elétrons, a luz incidente produz um sinal que pode ser medido eletronicamente. A estrutura básica de um tubo fotomultiplicador pode ser visualizada na Figura 5.5.

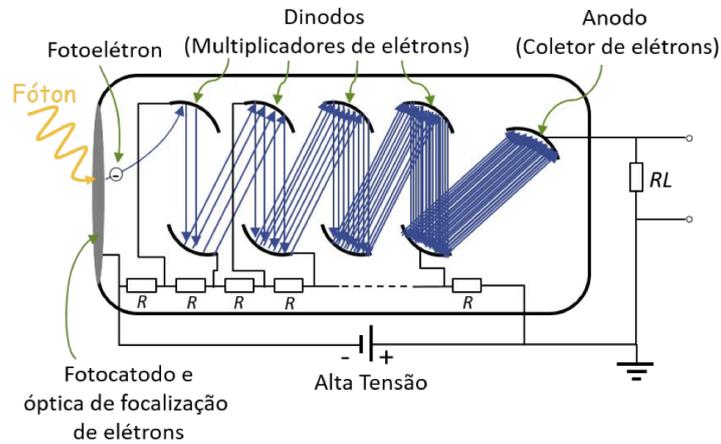


Figura 5.5: Estrutura básica de um tubo fotomultiplicador. Seus componentes essenciais são o fotocátodo, a óptica de focalização dos elétrons, os dinodos e o anodo. Extraído de [107].

Nas fotomultiplicadoras convencionais, a informação espacial da intensidade do sinal ao longo dos eixos x e y não pode ser acessada. Ao invés disso, todo o sinal luminoso, oriundo do aglomerado de fibras, é somado por um grande anodo, que intercepta todos os elétrons secundários. Porém, esta informação espacial pode ser recuperada através do uso de uma nova fotomultiplicadora com leitura multianodal, onde seus anodos estão dispostos em um arranjo quadrangular, adquirindo, desta forma, a distribuição bidimensional do sinal.

Como o espaço reservado para as PMT em cada módulo ainda será o mesmo após o *upgrade*, a nova fotomultiplicadora deverá ter as mesmas dimensões da fotomultiplicadora original. A escolha foi uma MA-PMT do fabricante *Hamamatsu*, modelo R7600 com 64 anodos distribuídos em uma grade de 8×8 *pixels*, que pode ser vista na Figura 5.6. O uso de MA-PMT's durante o *upgrade* também foi proposto por outros experimentos do LHC como o CMS [108, 109] e o LHCb [110, 111] durante seus programas de pesquisa e desenvolvimento.

Baseado em estudos realizados na área de testes do TileCal, bem como em análises realizadas por outros experimentos e pelo próprio fabricante [112], a opção pela leitura do conjunto de fibras com a fotomultiplicadora multianodal foi a solução escolhida. Um programa de testes para qualificar a operação da MA-PMT (modelo R7600) foi posto em operação desde o segundo semestre de 2016. Outras opções, como as fotomultiplicadoras de silício (SiPM) [113, 114] foram descartadas pois, devido às suas características eletrônicas, precisariam de uma reformulação substancial da cadeia de leitura atual.



Figura 5.6: A primeira fotomultiplicadora, da esquerda para a direita, possui leitura multianodal com 64 foto sensores distribuídos em uma grade de 8×8 *pixels* (modelo R7600). Ao lado, temos duas fotomultiplicadoras de anodo único, fabricadas especialmente para o TileCal (modelo R7877).

5.4 Acoplamentos Ópticos

Uma vez que as células do calorímetro possuem diferentes números de telhas cintiladoras, como pode ser visto na Tabela 3.1, ao juntar as extremidades de cada fibra conectada à essas telhas, temos conjuntos de fibras com diferentes diâmetros. A Figura 5.7 mostra uma representação da extremidade de um conjunto de fibras ópticas após serem combinadas e inseridas no misturador de luz. Como o número de fibras varia dependendo do tamanho da célula, conseqüentemente o diâmetro do conjunto dessas fibras também pode variar.

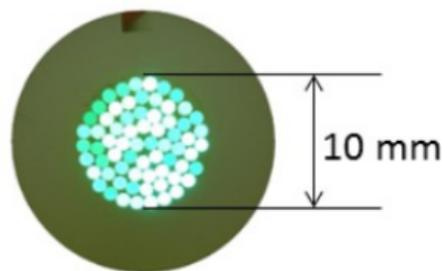


Figura 5.7: Representação em escala da face exterior de um conjunto de fibras.

Com isso, se faz necessário o desenvolvimento de conectores que auxiliem o acoplamento das fibras na superfície da fotomultiplicadora onde se encontra a matriz de *pixels*. As seções a seguir descrevem dois tipos de conectores desenvolvidos para esta tarefa. O primeiro trata-se de uma lente magnificadora, chamada de *Focon* (*Focusing Cone*) que tem a simples tarefa de ampliar a imagem formada pela extremidade do conjunto de fibras. O segundo conector é um Guia de Fibras (*Fiber Light Guide*), produzido com uma impressora 3D, e capaz de emular o arranjo de

pixels contidos na MA-PMT e, com isso, facilitar a associação de uma fibra com um único *pixel*.

5.4.1 Sistema de Lentes

A maneira mais simples de ampliar a imagem formada pelo conjunto de fibras na superfície da MA-PMT é através de uma lente magnificadora que, após ser inserida entre a extremidade de fibras e a MA-PMT, obtém um fator de ampliação duas vezes maior para as células BC e 3 vezes maior para as células da camada A. Para estudar os efeitos desta lente, uma área de testes foi construída pela colaboração TileCal, onde foram testadas lentes com distâncias focais diversas. A Figura 5.8 mostra como o padrão das fibras pode ser ampliado através deste sistema.

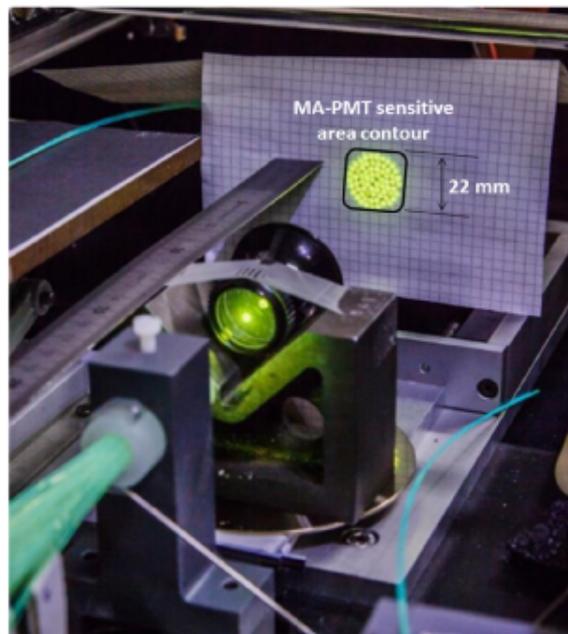


Figura 5.8: Ampliação da imagem formada pelo conjunto de fibras através de um sistema de lentes.

A praticidade, ao ter que desenvolver o mesmo acoplamento óptico para as milhares de células do calorímetro, aparece como uma vantagem para esta solução. Por outro lado, ampliar o padrão de fibras com o uso de uma lente magnificadora usa apenas $\pi/4$ do total de toda a área sensível da superfície da MA-PMT. Isto acontece uma vez que a imagem projetada é um círculo com diâmetro igual ao lado da área quadrada presente nos fotocátodos da MA-PMT.

5.4.2 Guia de Fibras

Um outro método diferente, capaz de mapear o conjunto de fibras em toda a área sensível presente no fotocátodo da MA-PMT, é a utilização de um Guia de Fibras.

Neste conector, as fibras que saem de uma das células do detector são acopladas em um guia óptico com novas fibras organizadas de forma a emular o arranjo de *pixels* da MA-PMT. Fibras que carregam a resposta individual de uma das telhas podem, desta forma, terem sido desviadas para o mesmo hemisfério ou quadrante de todo o fotocátodo e, em seguida, serem facilmente agrupadas para formar as novas subcélulas.

O Guia de Fibras foi produzido através de uma impressora 3D e o modelo usado para este trabalho pode ser visto na Figura 5.9 juntamente com suas dimensões. Com esse conector, toda a área sensível do fotocátodo presente na MA-PMT pode ser explorada, por conta da extremidade quadrangular do Guia de Fibras ser capaz de emular exatamente a matriz de *pixels*. Entretanto, temos 64 fibras fixas presentes no guia de fibras e, como já foi visto anteriormente, as células do TileCal possuem um número variado de fibras ópticas. Com isso, há uma perda durante a transmissão da luz ao passar da fibra original do detector para a fibra presente no Guia de Fibras.

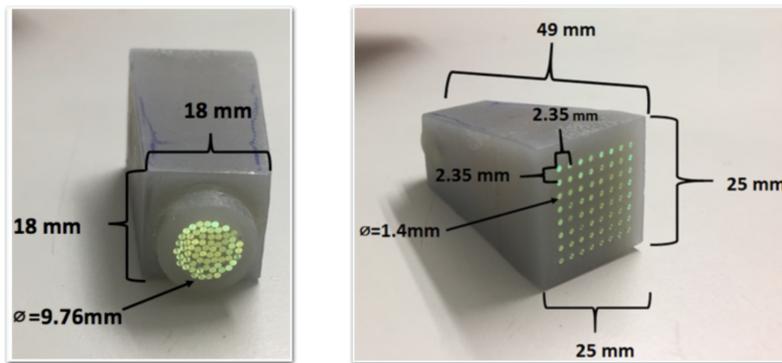


Figura 5.9: Guia de Fibras produzido pela impressora 3D.

O processo de impressão em larga escala destes conectores também pode ser feito facilmente, uma vez que os moldes necessários para a impressão estejam feitos de antemão de forma a ajudar a habilidade de prototipagem da impressora 3D. Para os diferentes diâmetros presentes nos conjuntos de fibras de todas as células do TileCal, serão necessários em torno de 5 modelos diferentes. Uma vez que os moldes estejam prontos, os conectores podem ser desenvolvidos em um tempo hábil.

5.5 Testes de Bancada

Durante o processo de pesquisa e desenvolvimento do projeto, uma bancada de testes foi montada, com um *mock up* do conjunto de fibras, para testarmos a eletrônica da MA-PMT, bem como seus diversos acoplamentos ópticos. O objetivo do estudo trata-se em decidir qual o acoplamento mais indicado para ser colocado entre o conjunto de fibras e a MA-PMT.

Na instrumentação de teste, uma luz LED ilumina uma única fibra do *mock up* do conjunto de fibras, e um total de três acoplamentos são testados: o guia de fibras 3D e dois sistemas de lentes, com diâmetros diferentes, chamados de cones focais (*Focusing Cones* - Focon), além dos testes sem nenhum acoplamento (*air gap*).

A Figura 5.10 mostra a variação da amplitude média para todos os acoplamentos testados. O eixo x marca a distância, em mm , do acoplamento até a MA-PMT. Vemos que o guia de fibras (em vermelho) perde até 50% de seu sinal quando comparado com a solução de lentes de maior diâmetro (verde). Isto se deve ao fato da luz que passa pelo guia, se dispersar na resina que compõe o seu material.

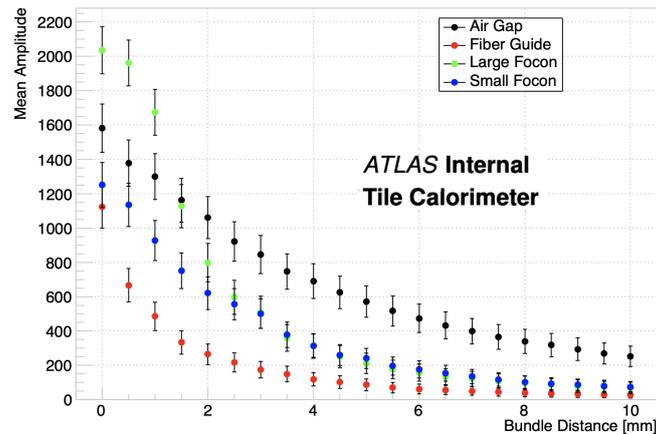


Figura 5.10: Amplitude média de sinal para diferentes acoplamentos ópticos, em função da sua distância com a MA-PMT.

A ausência de acoplamentos ópticos (em preto) apresenta a menor perda de amplitude, a partir de $1,5\text{ mm}$, porém ela não permite magnificar o arranjo circular do conjunto de fibras, Figura 5.7, de forma a cobrir toda a região do fotocatodo da MA-PMT. Com isso, a solução de lentes foi utilizada na coleta de dados deste trabalho, mais especificamente a lente grande, assim como todos os seus resultados, descritos em detalhe no Capítulo 6. A lente grande foi utilizada por possuir, dentro da faixa de incerteza, a mesma amplitude média que a lente pequena para a distância que usamos na instrumentação, entre $2,0\text{ mm}$ e $2,5\text{ mm}$.

Capítulo 6

Resultados

Este capítulo descreve os procedimentos, e resultados, utilizados no mapeamento do sinal proveniente do conjunto de fibras WSL, representados pela imagem formada na fotomultiplicadora multianodal, em novas subcélulas do calorímetro de telhas. Dois tipos de granularidades são propostas, como discutido na Seção 5.1, são elas: a granularidade transversal e a granularidade longitudinal.

Para testar a granularidade transversal usamos dados da célula A2, localizada na camada A do barril central do TileCal. Dividimos a célula A em duas novas regiões: partes esquerda e direita; dobrando a segmentação atual desta célula sem alterar a parte mecânica do detector e mantendo sua simetria. Neste caso a nova granularidade seria de $\Delta\eta \times \Delta\phi = 0,5 \times 0,1$.

Um método análogo permite buscar uma granularidade mais fina nas células da camada BC, neste caso, uma granularidade longitudinal que separe as células BC em duas células distintas B e C, como era a concepção inicial do detector. Para testar essa nova granularidade utilizamos dados da célula BC1 que também está localizada no barril central do TileCal. A Figura 6.1 mostra como fica a nova configuração de células após a nova proposta de divisão.

Redes Neurais Covolucionais (*Convolutional Neural Network* - CNN) [115], têm obtido sucesso em diversas aplicações numa ampla gama de trabalhos em Visão Computacional (*Computer Vision*), como, por exemplo, classificação de objetos [116], detecção de objetos [117] e segmentação [118], apenas para citar alguns. Os dois elementos principais que favoreceram esse tipo de algoritmos são: redes neurais com estrutura profunda, muitas camadas compondo as redes, e o uso de grandes bancos de dados anotados [119].

Os dados reais, coletados durante o processo de calibração de Césio, Seção 3.5, não possuem registros suficientes para serem usados nesses classificadores que, durante seu treinamento, precisam ajustar centenas de milhares de parâmetros. Portanto, utilizamos as chamadas Redes Adversariais Geradoras (*Generative Adversarial Networks* - GANs) [120] para criar dados sintéticos, com o objetivo de aumentar

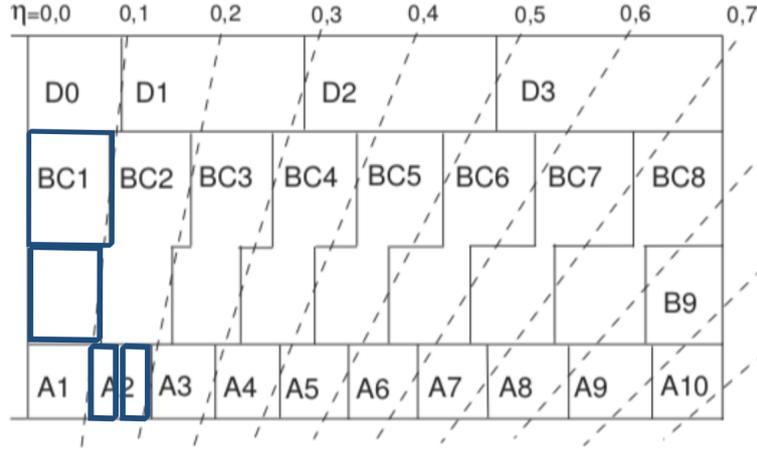


Figura 6.1: Nova granularidade, transversal e longitudinal. A linha em azul é uma representação da nova divisão das células BC1 e A2 que pode se estender para o restante das células nas suas respectivas camadas.

o numero de registros da amostra original de dados, fazendo com que a solução final seja composta destes dois tipos de algoritmos.

Ao final da geração de dados sintéticos, tratamos o problema da associação de imagens à regiões topológicas como um problema de classificação de imagens. Para isso, foram criados três pipelines de dados para alimentar algoritmos de Redes Neurais Convolucionais. Suas medidas de performance foram analisadas e a eficiência de classificação foi medida para diferentes faixas de energia.

6.1 Dados da Análise

Para realizar este mapeamento, utilizaremos os dados provenientes da calibração do detector com o sistema de Césio [121]. Neste sistema de calibração, uma varredura sobre todo o detector é feita através de uma fonte radioativa de ^{137}Cs , que ao mover-se ao longo do eixo z é capaz de excitar, sequencialmente, as telhas cintiladoras presentes nas células do calorímetro, tornando possível ordenar temporalmente a resposta individual de cada uma destas telhas. A Figura 6.2 mostra a cápsula de material radioativo dentro de um dos tubos por onde ela navega durante o processo de calibração.

Um sistema hidráulico é utilizado para mover a cápsula de ^{137}Cs por todo o detector, pelo interior de uma rede de tubos de metal, por onde a cápsula de material radioativo navega, inseridos em pequenos furos que atravessam cada uma das telhas cintiladoras, como pode ser visto na figura 6.3.

Escolhemos o sistema de Césio como fonte de dados da análise, pois além de termos uma radiografia completa de cada célula no TileCal, este sistema de calibração



Figura 6.2: Capsula de Césio, usada durante a calibração, dentro de um dos tubos por onde ela navega.

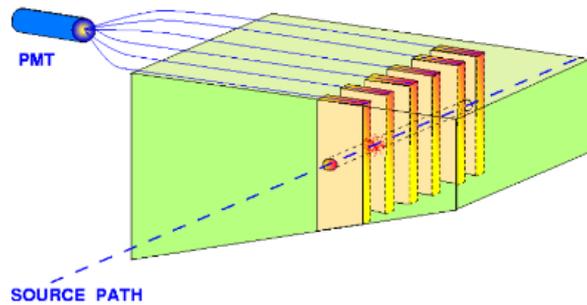


Figura 6.3: Fluxo percorrido pela cápsula de material radioativo, ^{137}Cs , ao passar pelas telhas do TileCal durante a calibração. Extraída de [121].

é o que mais se aproxima da detecção de partículas, encontradas na operação do detector.

A faixa de energia emitida pela fonte de Césio pode ser equiparada com a mesma faixa de energia de partículas reais, como por exemplo o Píon [122]. Os outros sistemas de calibração presentes no TileCal, Seção 3.5, não possuem essa característica, fazendo que optemos por esses dados em detrimento dos outros disponíveis.

Tomemos por exemplo a célula A12, uma das menores células do TileCal, presente no barril estendido. Esta célula possui, em sua geometria, três fileiras de material absorvedor e cintilador intercalados entre si. Cada uma destas fileiras possui nove telhas cintiladoras atuando como o material ativo. Ao realizarmos uma varredura com uma fonte de Césio nesta célula, obtemos o sinal representado na Figura 6.4 para a fileira mais próxima do feixe (*Tube #1*)¹.

Pode-se perceber que a fonte radioativa excita cada uma das telhas presentes na célula provocando o aparecimento de picos em seu sinal temporal. Ao analisarmos o sinal de uma destas fileiras, especificamente da célula A12, devemos encontrar nove picos em seu sinal, pois a célula A12 possui nove picos em cada uma de suas fileiras.

Cada telha cintiladora possui duas fibras WLS conectadas em cada uma de suas

¹As fileiras de telhas também são chamadas de *tubo*, uma vez que a cápsula de Césio passa por dentro de tubos de metal que, consequentemente, correspondem a cada uma das 11 fileiras de material ativo e passivo, presentes no TileCal.

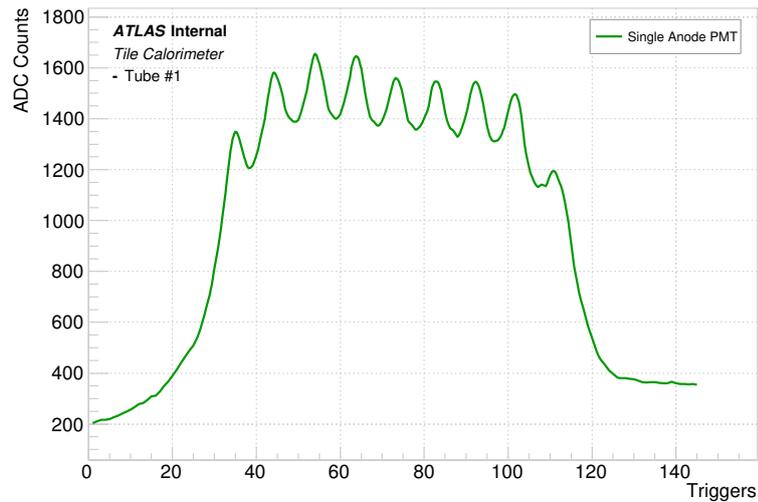


Figura 6.4: Sinal temporal para a primeira fileira da célula A12. Observamos nove picos, cada um deles corresponde à passagem da fonte de Césio por dentro de cada telha presente na fileira.

extremidades. Assim, para cada célula do TileCal temos dois canais de leitura, que correspondem ao conjunto de fibras que constitui uma célula. A Figura 6.5 mostra como os conjuntos de fibras são agrupados e instalados na parte externa de cada módulo do TileCal.

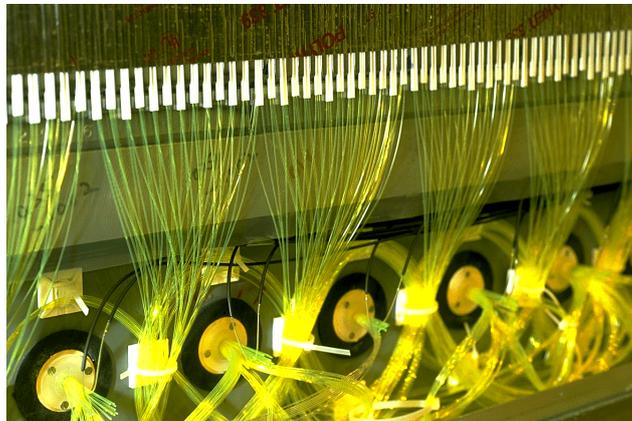


Figura 6.5: Instalação dos conjuntos de fibras, e seus misturadores de luz, na parte externa de um dos módulos do TileCal.

Com isso, o TileCal possui dois canais de leitura para a mesma célula, que, atualmente são lidos por fotomultiplicadoras de anodo único [123]. Ao substituírmos uma das PMTs de anodo único por uma MA-PMT, poderemos comparar a resposta temporal formada na PMT, como visto na Figura 6.4, com a imagem formada nos *pixels* da MA-PMT. Como ambas as PMTs estão lendo o mesmo sinal, torna-se possível associar regiões topográficas da célula com padrões de imagens formadas na MA-PMT. As Seções 6.1.1 e 6.1.2 descrevem em detalhes os dados utilizados no

desenvolvimento desse trabalho.

6.1.1 Dados da Célula A2

Os dados oriundos da calibração de Césio, são feitos através de varreduras (*cesium scans*), onde a cápsula de material radioativo trafega por todo o módulo do TileCal através de tubos que atravessam suas telhas. Para a configuração descrita anteriormente, em que uma mesma célula é lida por duas PMTs diferentes, uma com anodo único e outra com leitura multi-anodal, foram realizadas novos scans em caráter especial para a presente pesquisa.

Durante uma varredura completa, a cápsula de Césio sai da parte externa do modulo, percorre todas as suas células e retorna para o seu ponto inicial. Assim, todo o scan de Césio é sempre feito em pares; uma viagem de ida (*forward scan*) acompanhada da viagem de volta da cápsula (*backward scan*). A Tabela 6.1 mostra a quantidade de eventos, em cada varredura, feita para a célula A2, tanto de ida, quanto de volta, utilizando a nova cadeia de leitura com a MA-PMT. A pequena diferença na quantidade de eventos de cada varredura se dá ao fato da cápsula se atrasar ou se adiantar minimamente entre as suas viagens no módulo.

Tabela 6.1: Número de eventos para cada varredura realizada na célula A2. A letra F significa que o scan foi de ida, enquanto a letra B significa que o scan foi feito durante a volta da cápsula ao seu ponto inicial.

Varredura	Entradas
01F	520
02B	524
03F	524
04B	528
05F	524
06B	524
07F	524
08B	524
09F	522
10B	522
11F	520
12B	520
13F	516
14B	518
15F	520
16B	514

Um ponto importante durante o pré-processamento de dados para a célula A2, ou qualquer outras célula da camada A, é levar em consideração se a varredura sendo analisada foi uma varredura de ida ou de volta da cápsula de Césio. Uma vez

que pretendemos separar a célula A2 em duas sub-células transversalmente, parte esquerda e parte direita, é imprescindível que a dimensão temporal do sinal coletado seja a mesma que a dimensão espacial da célula.

Por exemplo, o primeiro pico do sinal temporal de um scan de ida corresponde à telha mais a esquerda da célula, enquanto o primeiro pico no sinal temporal de um scan de volta corresponde à telha mais a direita da célula, pois a cápsula de Césio está navegando no sentido contrário. Assim, devemos inverter o sinal para garantir que a dimensão temporal seja a mesma que a dimensão física percorrida durante a varredura.

A Figura 6.6 mostra o sinal temporal coletado nos três tubos da célula A2 para um dos scans utilizados nesse trabalho. Podemos ver que a célula A2 possui treze telhas em cada um dos seus três tubos. Também na Figura 6.6 podemos observar que os sinais temporais para os tubos #1 e #3 são similares, isso ocorre pois as telhas presentes nessas fileiras são lidas pela mesma fibra.

Após garantirmos que as varreduras correspondem à dimensão espacial do detector, podemos fazer um simples corte na metade do sinal temporal, coletado pela PMT de anodo único, a fim de separarmos as imagens, coletadas pela MA-PMT. Ou seja, as imagens que estão à esquerda do corte, correspondem a parte esquerda da célula, enquanto as imagens à direita do corte no sinal temporal, correspondem à região direita da célula.

Para garantir a repetibilidade da medição, todas as varreduras foram avaliadas para garantir que seu sinal temporal não tivesse diferença entre uma corrida e outra. Por exemplo, se uma telha apresenta um pico menor que os demais em uma corrida, a mesma telha deve apresentar um resultado similar para outras corridas, tanto de ida quanto de volta da cápsula de Césio.

6.1.2 Dados da Célula BC1

O pré-processamento dos dados da célula BC1, assim como o de qualquer outra célula da camada BC, difere do processamento feito para as células da camada A. Neste caso, desejamos uma granularidade longitudinal, logo não separamos mais a célula original em partes esquerda e direita; aqui as separações são feitas em subcélulas da parte superior e inferior. Esta nova segmentação leva em consideração o design original do TileCal, recuperando as células da camada B e C, separadamente.

Para a segmentação da célula BC utilizamos a informação de suas fileiras. Estas células possuem um total de seis fileiras, três fileiras (tubos) compondo a célula B e outras três fileiras (tubos) compondo a célula C. Como neste caso não estamos usando a informação espacial contida nos sinais temporais das varreduras de Césio, não se faz necessário inverter os sinais quando estamos processando um scan de volta

(*backward scan*). Diante disso, necessitamos apenas garantir que as imagens para a célula B são provenientes dos três tubos mais próximos do feixe de colisão, enquanto as imagens da célula C são resultantes dos tubos restantes.

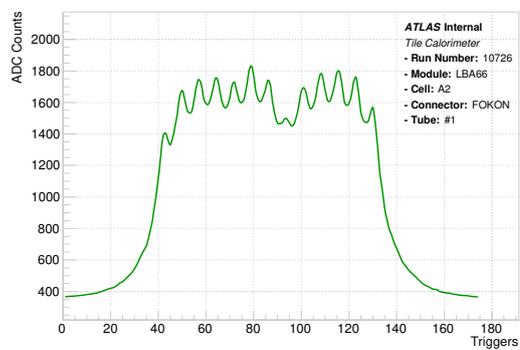
A Tabela 6.2 mostra a estatística coletada durante as varreduras de ida e de volta para a célula BC1 coletadas com a cadeia de leitura com duas PMTs, uma de anodo único e outra com leitura multi anodo. É possível ver que o número de eventos para esta célula é maior que o coleta para a célula A2, Tabela 6.1. Esse comportamento é esperado, uma vez que a célula BC1 é maior, e possui mais telhas, que célula A2.

Tabela 6.2: Número de eventos para cada varredura realizada na célula BC1. A letra F significa que o scan foi de ida, enquanto a letra B significa que o scan foi feito durante a volta da cápsula ao seu ponto inicial.

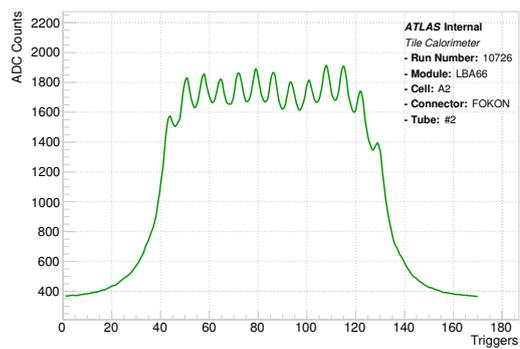
Varredura	Entradas
01F	1199
02B	1192
03F	1202
04B	1196
05F	1203
06B	1187
07F	1188
08B	1178
09F	1181
10B	1175
11F	1195
12B	1170
13F	1178
14B	1176
15F	1184
16B	1172
17F	1181
18B	1165
19F	1192
20B	1175

A Figura 6.7 mostra os sinais temporais para uma varredura na célula BC1. Nela podemos observar que os tubos #4 e #6 possuem um sinal temporal parecido, assim como as fileiras #7 e #9. Isso acontece, como na célula A2, porque as telhas nestas fileiras são lidas pela mesma fibra WSL. Também podemos observar que alguns picos não estão com o valor de amplitude próximo aos valores de seus picos vizinhos. Este tipo de comportamento pode ocorrer devido à uma fibra danificada, impossibilitando que todo o sinal coletado pela telha seja levado da telha até a fotomultiplicadora. Estes efeitos são corrigidos nas constantes de calibração, Seção 3.5, e aplicados na etapa de reconstrução de energia.

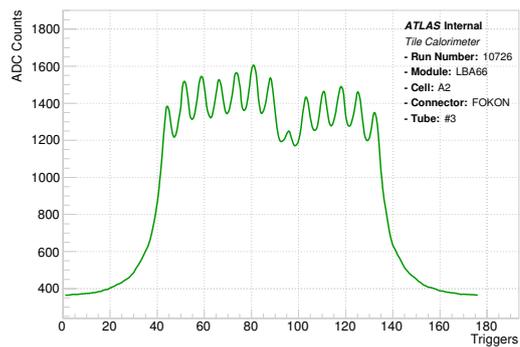
Utilizamos as imagens coletadas nos tubos 4, 5, e 6 como sendo relacionadas à sub-célula B, enquanto os tubos 7, 8 e 9 possuem as imagens da sub-célula C. Assim, com um conhecimento da geometria, e da instrumentação do detector, foi possível criar dois bancos de dados anotados que serão usados para alimentar os algoritmos de classificação de imagens baseados em Redes Neurais Convolucionais.



(a) Tubo 1

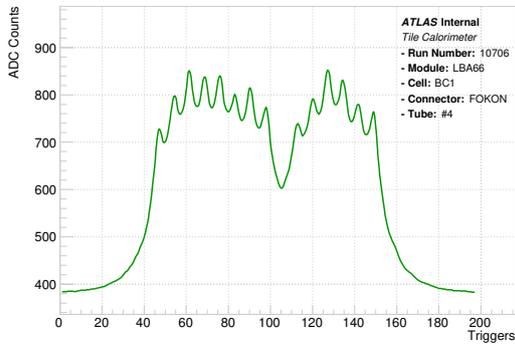


(b) Tubo 2

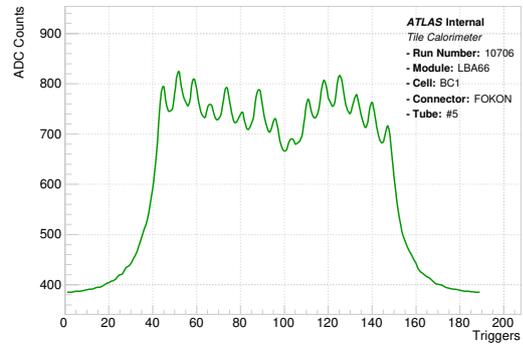


(c) Tubo 3

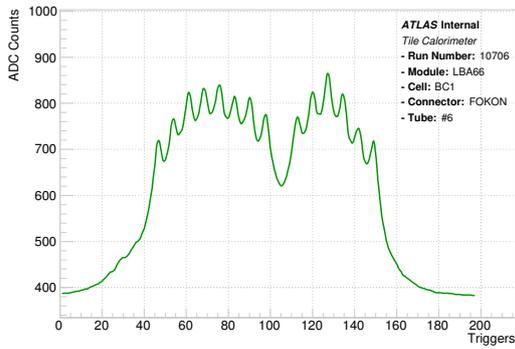
Figura 6.6: Sinal temporal para os três tubos que compõe a célula A2.



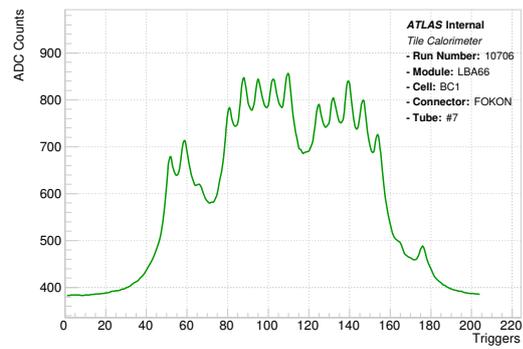
(a) Tubo 4



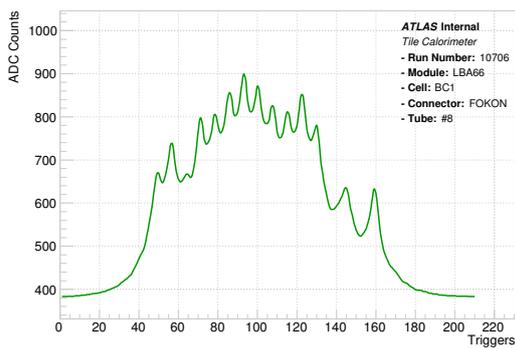
(b) Tubo 5



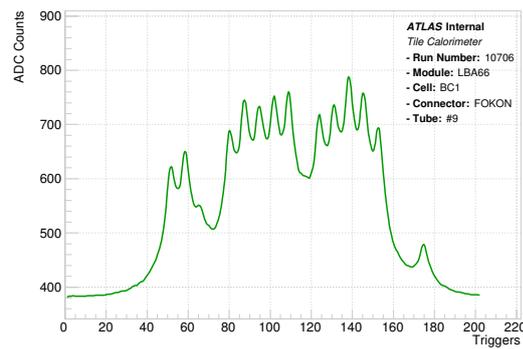
(c) Tubo 6



(d) Tubo 7



(e) Tubo 8



(f) Tubo 9

Figura 6.7: Sinal temporal para os seis tubos que compõe a célula BC1.

6.2 Proposta de Validação Cruzada

Com o objetivo de medir a incerteza estatística de cada uma das etapas presentes na solução do problema, devemos utilizar métodos estatísticos capazes de acessar toda a variabilidade da amostra de dados. Este processo é conhecido como Validação Cruzada (*Cross Validation*) [124, 125]. A validação cruzada do tipo *K-Fold* é a que mais se destaca entre as técnicas disponíveis [126]. Nela divide-se o conjunto de dados em k subconjuntos (também chamados de *fold* ou partições). Em seguida, o algoritmo em questão é treinado em $k-1$ partições dos conjuntos de dados; a partição que sobrou é usada para avaliar o treinamento, chamada de partição de teste. Este processo é repetido por k vezes, cada uma com um *fold* diferente, garantindo que todos os dados passem, pelo menos uma vez, no conjunto de teste.

Contudo, como as calibrações de Césio acontecem em pares, com a cápsula fazendo sempre duas viagens em cada varredura completa, uma viagem de ida (*forward scan*) seguida da viagem de volta (*backward scan*), propomos uma modificação na validação cruzada de forma a incluir a informação das varreduras em cada conjunto. A proposta é uma extensão do método *k-fold*, porém a partição que fica separada para o conjunto de teste corresponde à uma viagem completa (ida e volta) da cápsula de Césio dentro do módulo do TileCal. Neste caso, o tamanho de k depende de quantas varreduras estão disponíveis na amostra de dados. Como para a célula A2 temos $k = 8$, pois temos um total de 16 *scans*, enquanto $k = 10$ para a célula BC1, pois o total de varreduras é igual à 20.

A Figura 6.8 mostra como esse novo processo de validação cruzada é aplicado aos dados da célula A2. Nela vemos quais varreduras são separadas em cada partição. Apesar da figura mostrar apenas os dois primeiros *folds*, o processo segue até que a última viagem completa esteja separada para o conjunto de teste.

6.3 Geração de Dados Sintéticos

Como foi discutido anteriormente, a coleta de dados através da varredura dos módulos do TileCal com uma cápsula de Césio, exige planejamento e mão de obra especializada devido à complexidade dos instrumentos envolvidos no processo. Além disso, esse tipo de aquisição é feito somente quando não há colisões em andamento no detector; e quando ocorre é limitado a algumas dezenas de varreduras por célula, para garantir que todas os 64 módulos do TileCal sejam calibrados igualmente.

As Tabelas 6.1 e 6.2 mostram a ordem da quantidade de dados coletada durante essas varreduras. Pode-se notar que não há estatística suficiente para alimentar algoritmos de reconhecimento de imagens baseados em Aprendizado Profundo. Isso ocorre porque algoritmos treinados sob este paradigma necessitam ajustar, durante

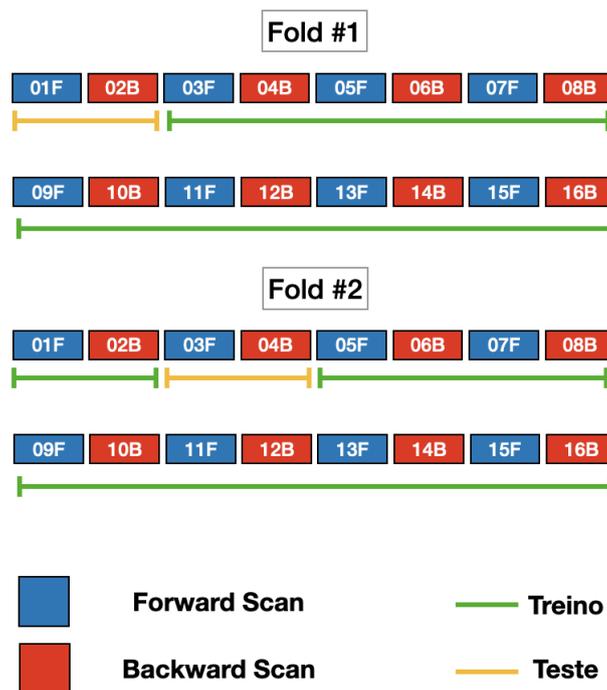


Figura 6.8: Exemplo da validação cruzada usada no trabalho. A figura mostra as duas primeiras partições para a validação aplicada nos dados da célula A2.

sua etapa de otimização, centenas de milhares de parâmetros a fim de obter uma performance de classificação acurada. Caso treinássemos uma rede convolucional, por mais simples que seja, apenas com a estatística presente nessa aquisição de dados, não teríamos graus de liberdade suficiente para que o modelo fosse treinado.

Dado este obstáculo, o presente trabalho sugere a criação de dados sintéticos que atuarão em conjunto com os dados reais de calibração em diferentes pipelines de classificação. Para a geração destes dados usamos um algoritmo generativo, baseado em redes neurais, que possui um treinamento adversarial. As Redes Generativas Adversariais (GAN), como são chamadas, são um tipo de modelo generativo implícito, capazes de aprender uma função geradora responsável por criar imagens sintéticas com estrutura estatística similar à amostra original. A Seção 6.3.1 detalha o processo de treinamento e da GAN utilizada neste trabalho, enquanto as Seções 6.3.2 e 6.3.3 resumizam os resultados obtidos para as imagens sintéticas geradas para as células A2 e BC1.

6.3.1 Redes Generativas Adversariais

Um dos problemas centrais da área de processamento de sinais e estatística consiste na estimação da densidade de probabilidade de uma amostra de dados. Ou seja, encontrar meios de se obter uma representação, paramétrica ou não paramétrica, de dados do mundo real. Esta é a motivação principal das GANs [127]. Estas redes

aprendem a minimizar uma medida de similaridade entre a distribuição de dados do modelo e a distribuição de dados reais, permitindo sintetizar amostras de dados através da função geradora encontrada após o processo de otimização do modelo.

Neste trabalho, aplicamos uma variante das GANs, chamada de DCGAN [128], baseada em Redes Neurais Convolucionais, para simular a interação de partículas dentro das células do TileCal, e, assim, aumentar substancialmente a quantidade de dados disponíveis para a etapa de classificação. Uma variedade de GANs já foi utilizada em trabalhos de física a fim de se obter dados simulados de maneira mais rápida e eficiente [129, 130].

Na proposta original de redes generativas temos dois modelos com redes *Multi Layer Perceptron* (MLP) [131]. A primeira rede, chamada de rede *geradora*, aprende um mapeamento $x = G(z; \theta_g)$, sobre o espaço de dados x , onde θ_g são os parâmetros da rede e z é um vetor de entrada contendo apenas ruído. Enquanto a segunda rede MLP, chamada de rede *discriminadora*, possui um mapeamento $D(x; \theta_d)$, que representa a probabilidade dos dados x serem dados reais ou dados gerados pela rede G [120]. As funções D e G jogam um jogo de *minimax*, onde o equilíbrio é o ponto de sela sobre a função:

$$J^{(D)} = -\frac{1}{2}\mathbb{E}_{x \text{ p dados}} \log D(x) - \frac{1}{2}\mathbb{E}_z \log(1 - D(G(z))). \quad (6.1)$$

Em outras palavras, a finalidade da função geradora é criar imagens sintéticas cada vez mais parecidas com as imagens reais, enquanto a rede discriminadora tem o simples papel de classificar as imagens como originais ou falsas; por imagens falsas entendemos as imagens que não vieram da mesma distribuição de probabilidade dos dados de treinamento. O treinamento é finalizado quando a rede discriminadora não consegue mais distinguir entre as imagens sintéticas e originais. A Figura 6.9 mostra um diagrama onde as duas redes neurais são treinadas dentro do modelo adversarial.

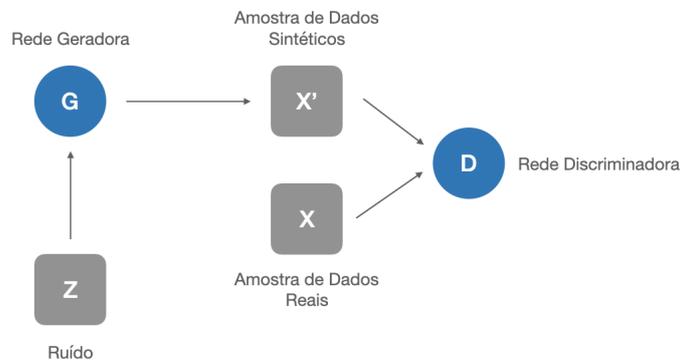


Figura 6.9: Representação de como os modelos Gerador e Discriminador são treinados simultaneamente no modelo adversarial.

Como as imagens formadas na MA-PMT possuem o mesmo tamanho tanto para a célula A2, quanto para a célula BC1, a arquitetura das redes generativas foi a mesma para as duas células. Como temos imagens de 8×8 pixels, as camadas de convolução e *pooling* das redes, generativa e discriminadora, foram ajustadas de acordo com o tamanho da imagem de entrada.

Na rede geradora temos três camadas convolucionais com filtros de tamanho 128, 64 e 1, respectivamente. Todas as convoluções utilizam *kernels* com tamanho 3×3 e *strides* 1. A função de ativação ReLU (*Rectified Linear Unit*) [132] é usada em todas as camadas, com exceção da última que possui função tangente hiperbólica. A arquitetura da rede geradora é sumarizada na Tabela 6.3.

A rede discriminadora possui quatro camadas convolucionais ativadas com a função LeakyReLU [133] e parâmetro $\alpha = 0.2$. Sua última camada trata-se de uma camada densa com função de ativação sigmóide. As duas primeira convoluções possuem filtros de tamanho 32 e 64, respectivamente, *kernels* de tamanho 3×3 e *strides* 2. Seguidas de mais duas camadas convolucionais de tamanho 128 e 256, *kernels* de tamanho 3 e *strides* de tamanho 1. A rede discriminadora tem sua arquitetura detalhada na Tabela 6.4.

Tabela 6.3: Arquitetura usada na rede Geradora.

Camada	Filtros	<i>Kernels</i>	<i>Strides</i>	Função de Ativação
Conv. 2D	128	3	1	ReLU
Conv. 2D	64	3	1	ReLU
Conv. 2D	1	3	1	ReLU
Densa	1	<i>None</i>	<i>None</i>	tanh

Tabela 6.4: Arquitetura usada na rede Discriminadora.

Camada	Filtros	<i>Kernels</i>	<i>Strides</i>	Função de Ativação
Conv. 2D	32	3	2	LeakyReLU
Conv. 2D	64	3	2	LeakyReLU
Conv. 2D	128	3	1	LeakyReLU
Conv. 2D	256	3	1	LeakyReLU
Densa	1	<i>None</i>	<i>None</i>	Entropia Cruzada

O modelo adversarial foi treinado usando o algoritmo de otimização Adam [134], com taxa de aprendizado 0,0002. Para evitar instabilidades durante o treinamento, foi aplicada uma normalização por batelada (*batch normalization*) em todas as camadas das redes, com exceção da primeira camada da rede Discriminadora e da última camada da rede Geradora. As redes foram treinadas por 5000 épocas ou até não haver alterações no erro de classificação da rede Discriminadora por 5 épocas

seguidas. Os resultados para as imagens sintéticas, que serão usadas para compor os pipelines de classificação, são descritas nas Seções 6.3.2, célula A2, 6.3.3, para os resultados da célula BC1.

6.3.2 Imagens Sintéticas para a Célula A2

Os resultados apresentados nessa seção correspondem às imagens sintéticas encontradas para as partes esquerda e direita da célula A2, correspondendo à nova granularidade transversal, mostrada na Figura 6.1. Portanto foram treinadas redes adversariais especializadas em cada sub-célula proposta pela nova segmentação. Ou seja, temos uma rede generativa para a parte esquerda da célula A2, e uma nova rede generativa para a parte direita da célula. Todos os resultados apresentados aqui correspondem à partição de teste que obteve o menor erro médio, pixel por pixel, entre imagens reais e sintéticas.

Para avaliar o resultado do treinamento, foram geradas imagens sintéticas em mesma quantidade que as imagens reais presentes na partição de teste. A Figura 6.10 mostra a intensidade média entre pixels para as imagens reais e sintéticas correspondentes à parte esquerda da célula A2. Apesar da MA-PMT conter um total de 64 pixels em sua grid, pode-se notar que temos apenas 48 pixels ativos na figura. Isso ocorre devido à limitações na eletrônica de leitura da MA-PMT; porém fornece a possibilidade de mimetizar um arranjo circular para a imagem, assim como é visto no aglomerado de fibras que correspondem à célula, Figura 5.7.

A mesma comparação entre imagens reais e sintéticas também é feita para a parte direita da célula A2, como mostra a Figura 6.11. Todas as imagens foram normalizadas para terem 8 *bits* antes da comparação. Isso faz com que a faixa dinâmica de seus pixels permaneça entre os valores 0 e 255. Em ambas figuras, 6.10 e 6.11, podemos observar que as imagens sintéticas capturam de forma correta o formato circular das imagens reais, deixando inativos os pixels ao redor da borda da imagem.

A Figura 6.12 mostra o erro médio entre as imagens, calculado pixel à pixel. Nela podemos ver que as imagens sintéticas reconstroem bem a estrutura de pixels contida nas imagens reais, com a ressalva de que as imagens da parte direita tiveram um erro maior em comparação às imagens da parte esquerda. O erro da sub-célula esquerda tem seu valor máximo em 1%, enquanto o erro médio das imagens da sub-célula direita pode chegar até 6% em alguns pixels.

Vale ressaltar que um erro relativo próximo de zero, não necessariamente significa um resultado favorável, pois o objetivo das imagens sintéticas neste estudo não trata-se apenas de copiar a distribuição de probabilidade das amostras contidas no conjunto de treinamento; também estamos interessados que a rede geradora seja

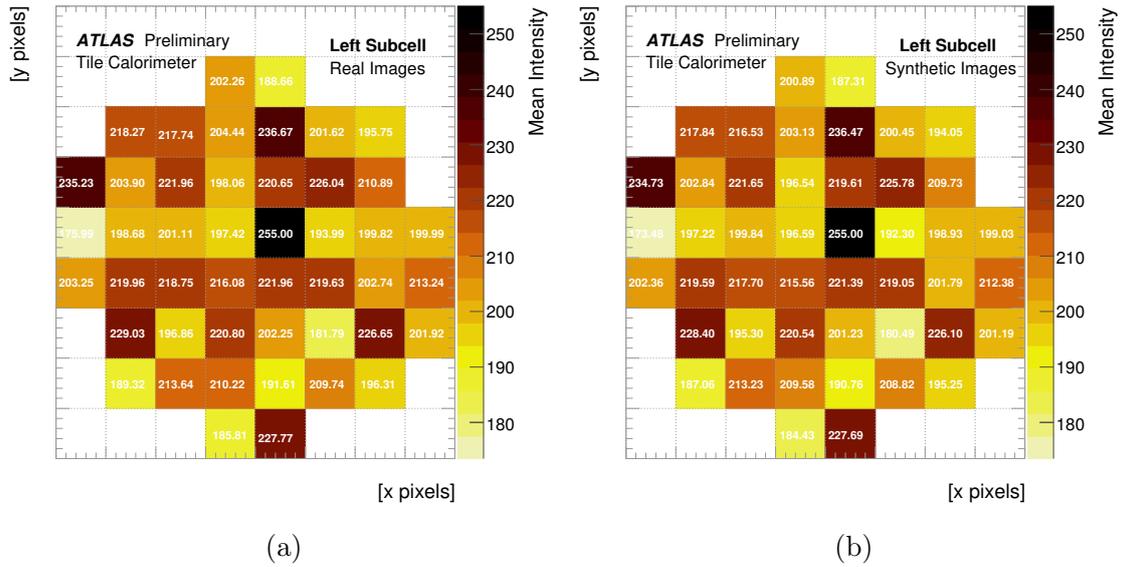


Figura 6.10: Comparação entre imagens reais (a) e sintéticas (b) para a parte esquerda da célula A2.

capaz de criar diversidade em suas imagens sintéticas. Caso a rede seja capaz de criar novas imagens sintéticas, com um certo grau de diversidade, conseguiremos assim acessar partes da distribuição de probabilidade da população original que não estava disponível na nossa amostra original de dados por conta de sua estatística limitada.

Assim, um erro da ordem de aproximadamente $5\% \approx 6\%$ pode ser considerado positivo. Os impactos da diversidade da amostra de dados sintéticos também podem ser avaliados na etapa final de classificação deste estudo, onde examinamos o efeito dos dados sintéticos nas medidas de performance de classificação das imagens.

Como, ao final do estudo, vamos utilizar as imagens sintéticas como dados de entrada para o classificador neural, também devemos avaliar se estas imagens acompanham a diferença no padrão entre as classes para a qual deseja-se treinar o classificador. Ou seja, a diferença entre a estrutura das imagens, que caracterizam os depósitos de energia, das partes esquerda e direita da célula A2 deve se manter similar também para os dados sintéticos. Para essa avaliação, foi calculado o erro relativo entre os valores médios de pixels das imagens das classes H0 (esquerda) e H1 (direita).

A Figura 6.13 mostra a comparação do erro relativo entre classes, tanto para as imagens reais quanto para as imagens sintéticas. Vemos que nas imagens reais existe uma diferença entre a deposição de energia, com valores mais baixos que os outros pixels, na região inferior esquerda da imagem. Este comportamento também é acompanhado pela diferença entre classes, esquerda e direita, calculadas para as imagens sintéticas. Portanto, podemos concluir que as imagens sintéticas foram

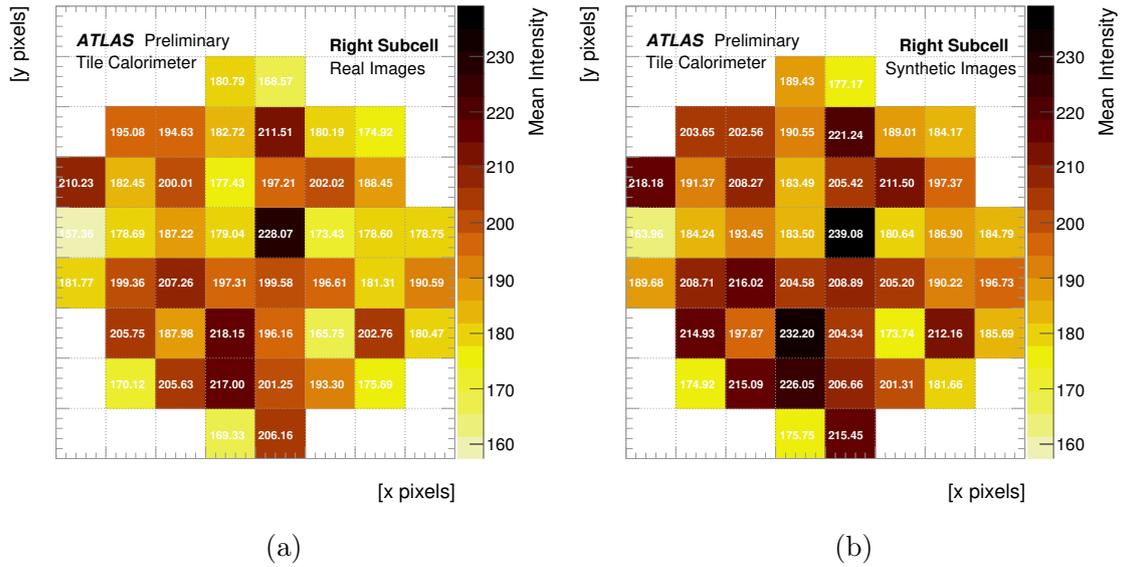


Figura 6.11: Comparação entre imagens reais (a) e sintéticas (b) para a parte direita da célula A2.

capazes de capturar as pequenas nuances que diferem uma imagem da sub-célula esquerda de uma imagem da sub-célula direita.

Uma outra forma de comparar a qualidade das imagens sintéticas consta em criar a distribuição de intensidade de pixels e avaliar tanto seus valores estatísticos, média e variância, como o formato de suas distribuições. Para isso, percorremos todos os valores de pixels presentes nas imagens reais e sintéticas, separadamente, e montamos seus respectivos histogramas.

A Figura 6.14 mostra estes resultados, excluindo o bin de valor zero, que neste caso, possuem o mesmo valor tanto para as imagens reais quanto para as imagens sintéticas. O histograma da cor azul corresponde à distribuição de dados reais, enquanto o histograma da cor vermelha mostra a distribuição de pixels das imagens sintéticas geradas pela rede geradora.

Para as intensidades da sub-célula esquerda vemos uma distribuição bi-modal concentrada na região central do histograma. Este comportamento também é capturado pela distribuição das imagens sintéticas, em vermelho. Há também um depósito de eventos concentrados no pixel de maior valor, 255, em que as intensidades das imagens sintéticas também conseguem acompanhar. A média e o desvio padrão das duas distribuições possuem o mesmo valor, dentro das suas barras de incerteza estatística.

Quando analisamos as intensidades da sub-célula direita ainda vemos a estrutura bi-modal. Porém, há também uma cauda na distribuição entre a faixa de 100 à 180, assim como um depósito de pixels com seu valor máximo de 255. Da mesma forma, vemos a distribuição de intensidade dos dados sintéticos, em vermelho, acompanhar

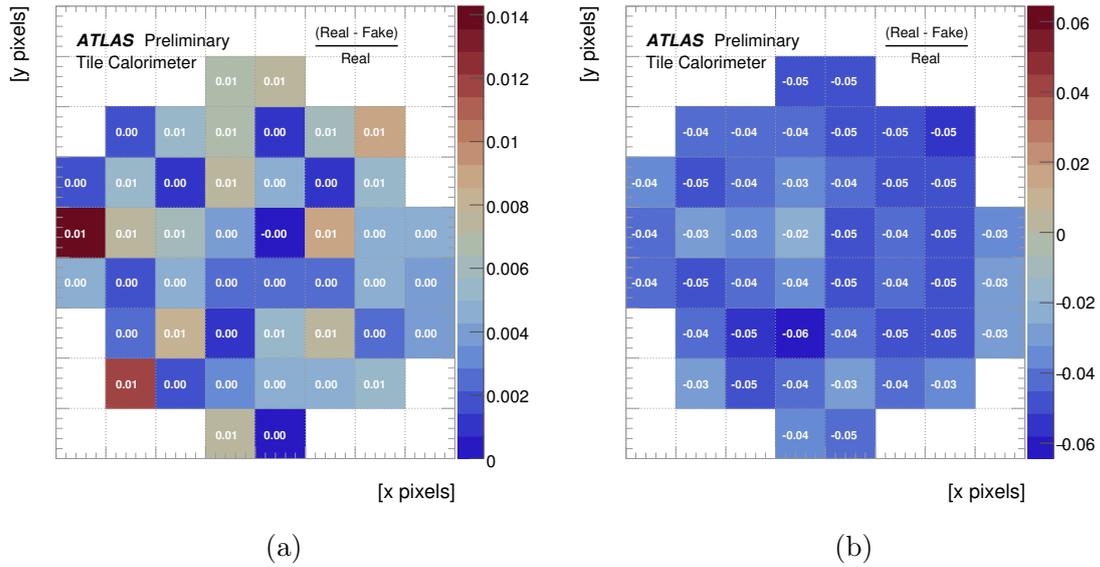
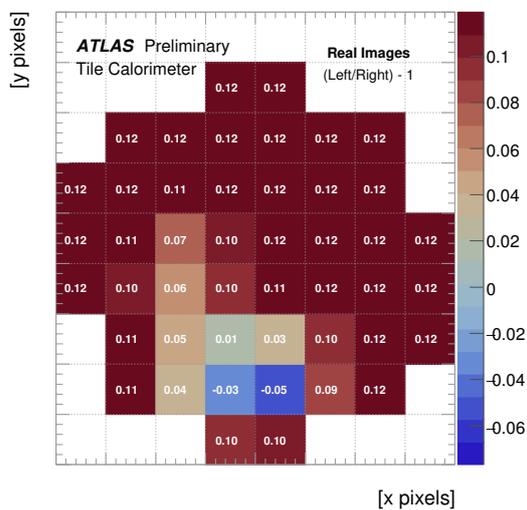


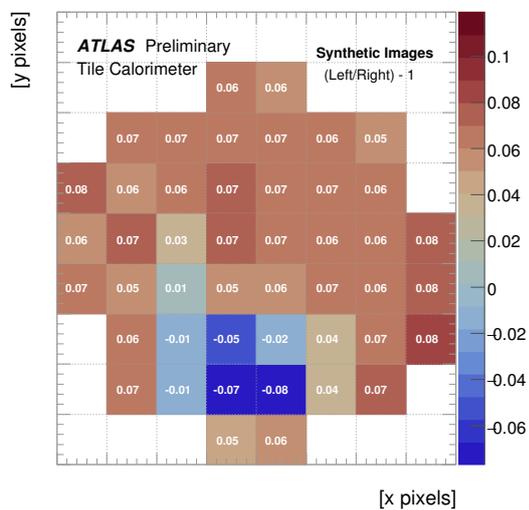
Figura 6.12: Erro médio, calculado pixel à pixel, entre imagens reais e sintéticas para a sub-célula esquerda (a) e direita (b) da célula A2.

esses comportamentos presentes na distribuição de dados reais (azul). As distribuições também apresentam medidas de média e desvio padrão compatíveis, dentro de suas faixas de incerteza.

Com isso, finalizamos o processo de geração e avaliação de imagens sintéticas para as partes esquerda e direita da célula A2. Caracterizando a nova granularidade transversal proposta para a camada A do calorímetro de telhas. com base em um banco de dados anotados de imagens reais e sintéticas podemos prosseguir com o estudo e avaliar a performance dos classificadores neurais alimentados por essas imagens. Porém, antes disso, também se faz necessário criar uma rede geradora para a nova granularidade proposta para as células BC. Este ponto é discutido na Seção 6.3.3 através da mesma análise discutida aqui.

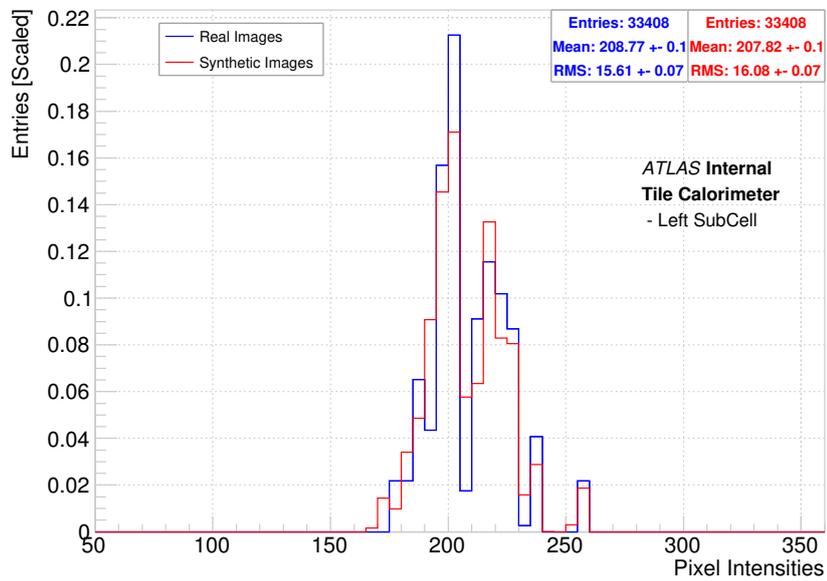


(a)

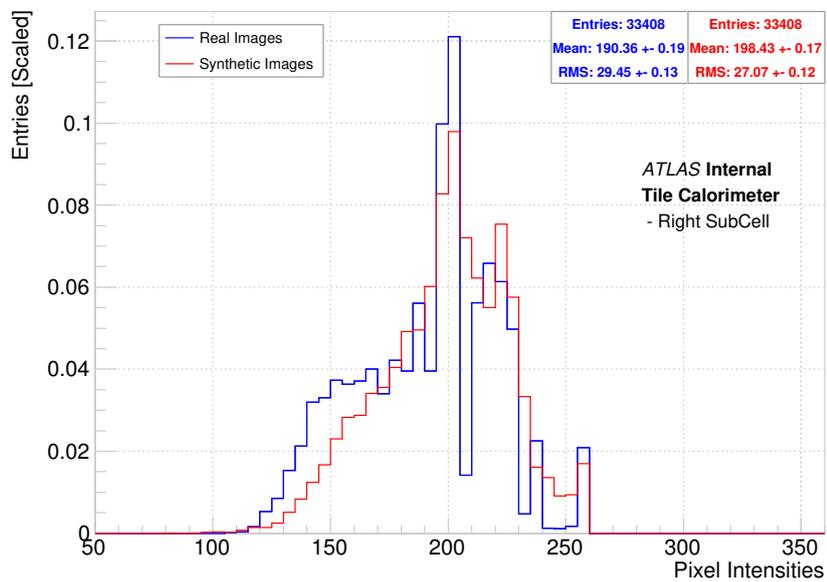


(b)

Figura 6.13: Erro relativo entre as classes esquerda e direita para imagens reais (a) e sintéticas (b).



(a)



(b)

Figura 6.14: Intensidade de pixels reais (azul) e sintéticos (vermelho) para as sub-células esquerda (a) e direita (b) da célula A2.

6.3.3 Imagens Sintéticas para a Célula BC1

Nesta seção vamos avaliar as imagens sintéticas geradas para a nova granularidade proposta para as células BC. Uma granularidade longitudinal que recupera a segmentação do TileCal em sua concepção original, com duas células distintas B e C, separadas umas das outras.

Neste caso, também foram treinadas separadamente redes generativas adversariais para as duas sub-células B e C. Assim como na Seção 6.3.2, todos os resultados mostrados aqui correspondem à partição de validação cruzada com o menor erro médio de reconstrução entre imagens reais e sintéticas. Todas as imagens foram normalizadas para terem 8 *bits*, com suas intensidades de pixels variando entre 0 e 255.

A Figura 6.15 mostra a intensidade média de pixels para as imagens reais e sintéticas da célula B. Enquanto a Figura 6.16 mostra a intensidade média para as imagens da célula C. Aqui, novamente, as imagens sintéticas capturam o formato circular das imagens reais, mostrando apenas seus 48 pixels ativos, formando o mesmo arranjo circular encontrado nas imagens coletadas com dados reais provenientes da calibração de Césio.

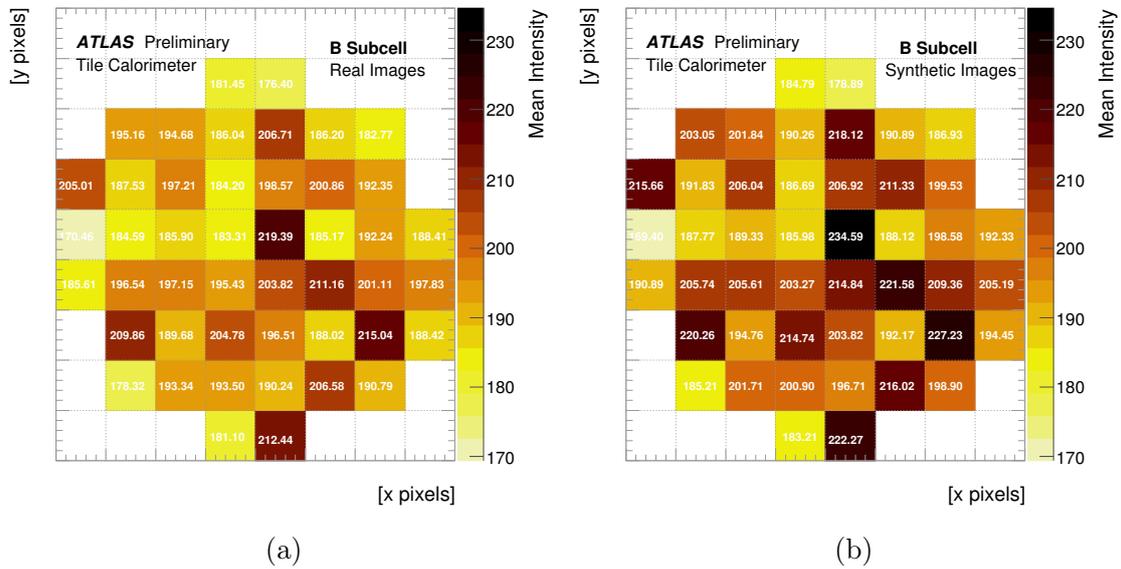


Figura 6.15: Comparação entre imagens reais (a) e sintéticas (b) para a sub-célula B.

O erro relativo por pixels é mostrado na Figura 6.17. Para ambas as novas sub-células, B e C, o erro relativo entre as imagens reais e sintéticas é da ordem de 6% \approx 7%, caracterizando uma boa reconstrução das imagens originais, sem comprometer a geração de imagens diversificadas que não estão contempladas na amostra de dados reais coletada durante a calibração.

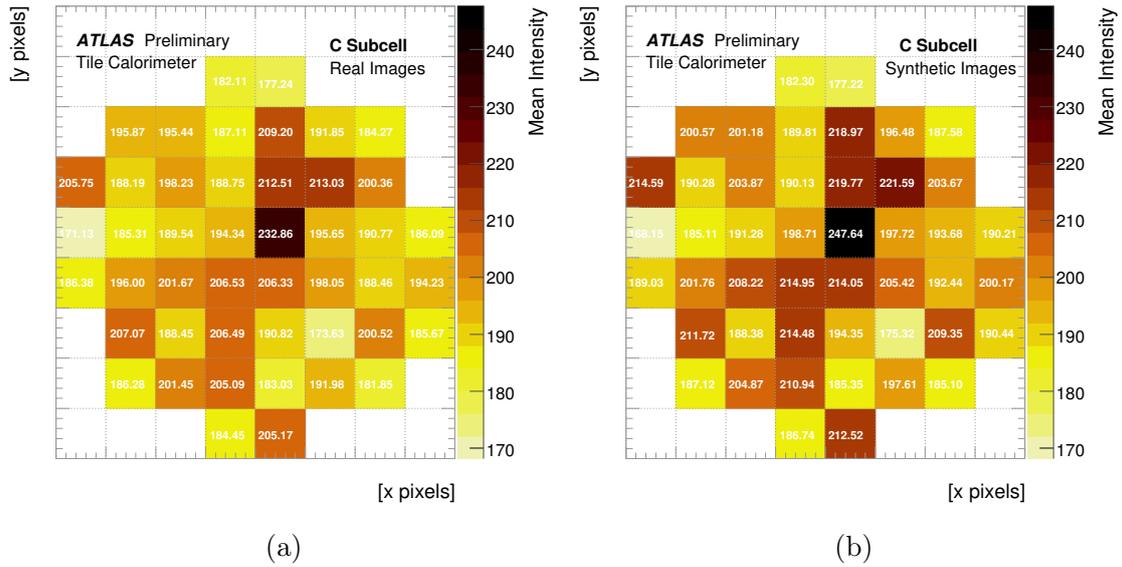


Figura 6.16: Comparação entre imagens reais (a) e sintéticas (b) para a sub-célula C.

Para avaliar se as imagens sintéticas conseguiram capturar o padrão de pixels que separa as classes H0 (célula B) da classe H1 (célula C) analisamos o erro relativo entre as classes, mostrado na Figura 6.18. Nesta figura observamos que o padrão que separa as classes possui valores altos na região inferior direita e valores baixos presentes na região da diagonal secundária que corta a imagem. Ambos os padrões de separação entre as classes B e C são bem capturados pelas imagens sintéticas. Consequentemente, podemos concluir que para a granularidade longitudinal, as imagens sintéticas também foram capazes de capturar as particularidades que separam as classes.

Por último, avaliamos a distribuição das intensidades de pixels para as células B e C, tanto para dados reais, quanto para dados sintéticos. As distribuições de dados podem ser vistas na Figura 6.19. A distribuição de dados reais (azul) para a sub-célula B possui um aglomerado de entradas ao redor da intensidade de pixel com valor de, aproximadamente, 160; enquanto a distribuição das imagens sintéticas tenta minimizar essa distância com uma cauda que se estende pela parte esquerda da distribuição.

A distribuição das imagens reais para a sub-célula C apresenta o mesmo comportamento, porém com pouca ênfase quando comparado com sua outra sub-célula. Neste caso, a distribuição das imagens sintéticas tenta minimizar sua distância com a distribuição de dados reais através de uma cauda que também se estende pela parte esquerda do gráfico. Ambas as sub-células possuem um depósito de eventos no bin de maior valor, 255, que são prontamente acompanhados pela distribuição dos dados sintéticos.

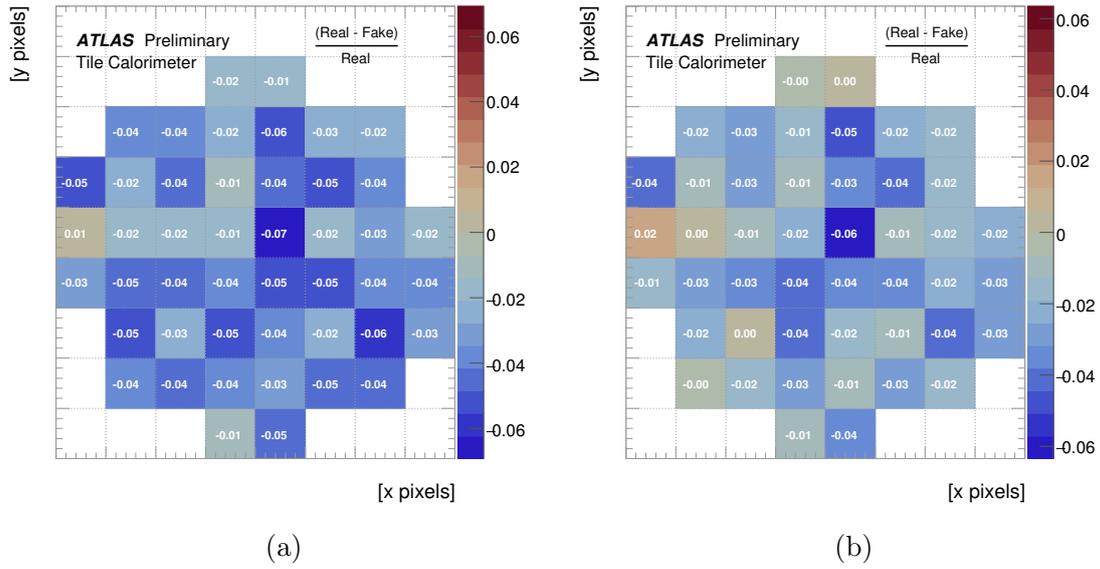
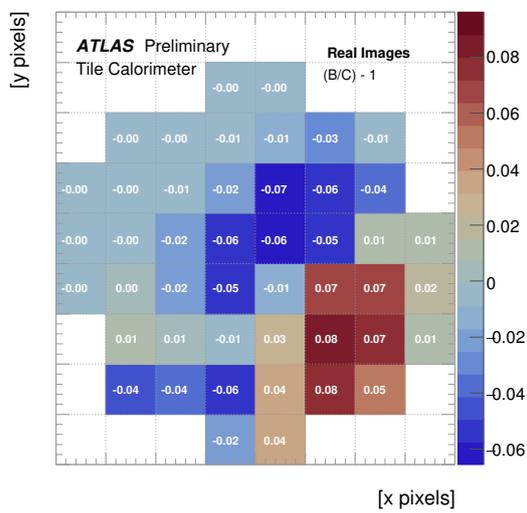
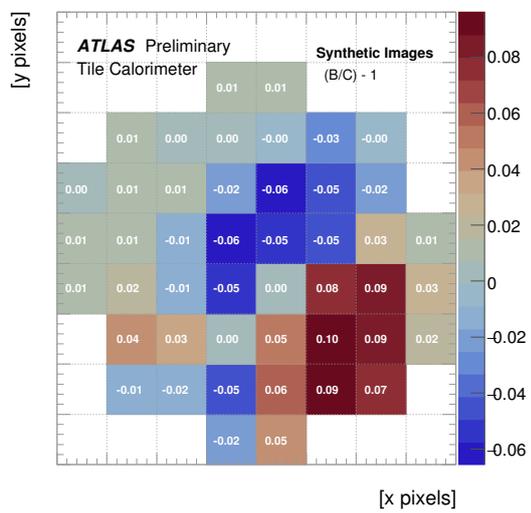


Figura 6.17: Erro médio, calculado pixel à pixel, entre imagens reais e sintéticas para a sub-célula B (a) e C (b) da célula BC1.

Com isso, também finalizamos a etapa de criação das redes geradoras para a nova granularidade longitudinal. Concluindo que as imagens sintéticas criadas por ambas as redes representam bem as imagens reais coletadas durante a aquisição de dados. Assim, obtém-se um mecanismo de geração de amostras que pode ser utilizado para aumentar a estatística do problema, que é bastante reduzida devido à natureza da coleta de dados reais. Esta técnica se mostra bastante vantajosa, sendo possível aumentar em várias ordens de magnitude as centenas de dados originais produzidos pela calibração de Césio.

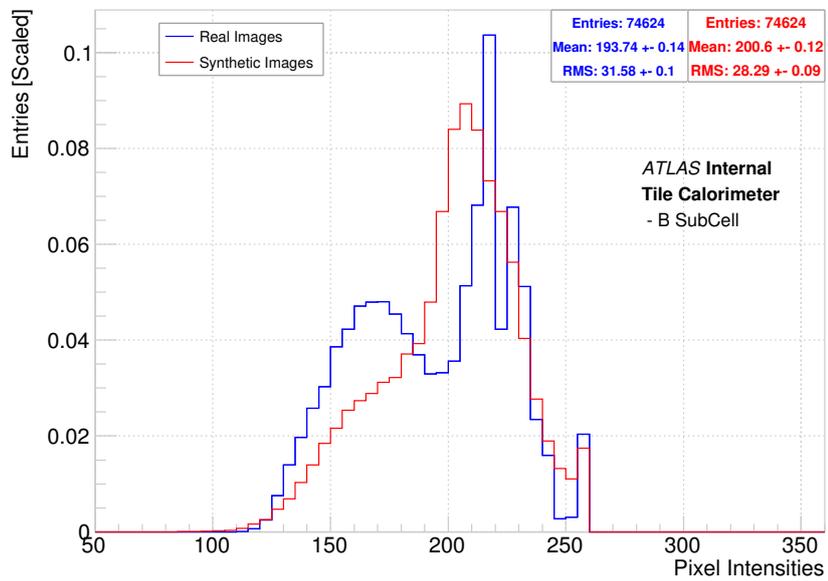


(a)

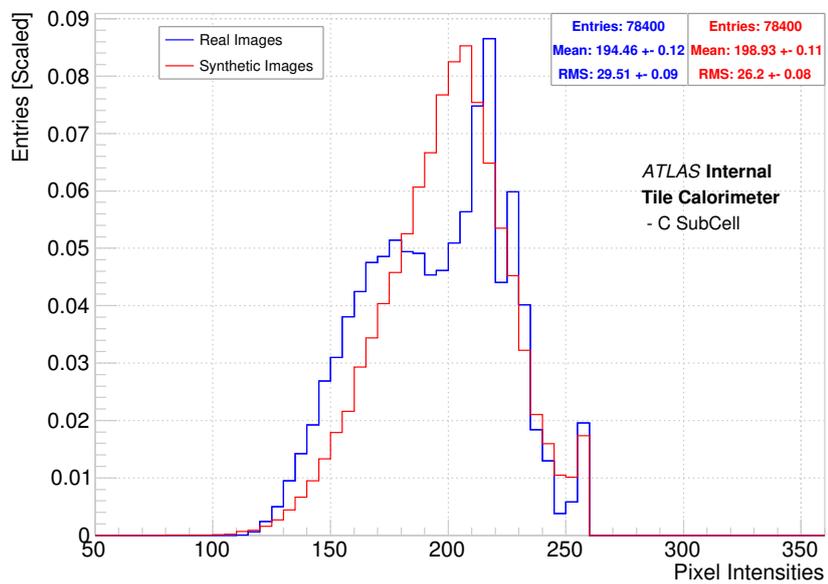


(b)

Figura 6.18: Erro relativo entre as classes B e C para imagens reais (a) e sintéticas (b).



(a)



(b)

Figura 6.19: Intensidade de pixels reais (azul) e sintéticos (vermelho) para as sub-células B (a) e C (b) da célula BC1.

6.4 Pipelines de Classificação

Com as imagens reais e sintéticas em mãos, podemos iniciar o processo de treinamento dos classificadores neurais que irão avaliar se um padrão de imagem formada na MA-PMT corresponde à uma determinada região topográfica do TileCal. A criação de um banco de dados anotado, permitiu olharmos para o problema sobre a ótica do Aprendizado Supervisionado. Sendo assim, os modelos de classificação usados neste trabalho, são baseados em Redes Neurais Convolucionais [135–137], devido ao seu sucesso em diversas aplicações em classificação de imagens.

Esta seção descreve brevemente os algoritmos de Aprendizado Profundo (*Deep Learning*) baseados em redes neurais com camadas convolutivas, Seção 6.4.1. Em seguida, apresentamos os resultados de classificação para três pipelines distintos. Cada pipeline utiliza os dados sintéticos, mostrados na Seção 6.3, de maneiras diferentes. O primeiro pipeline, Seção 6.4.2, utiliza os dados sintéticos para treinar o algoritmo de classificação, enquanto o segundo pipeline, Seção 6.4.3, treina as redes convolucionais com uma combinação de dados reais e sintéticos em cada batelada, e o último pipeline faz um ajuste fino (*fine tuning*) com dados reais nas redes que foram treinadas com dados sintéticos.

A Figura 6.20 mostra um esquema completo da análise. As setas de cor azul representam o segundo e terceiro pipeline, pois eles se utilizam de dados reais, seja em conjunto com dados sintéticos ou separadamente no processo de ajuste fino. Também é importante ressaltar que a avaliação do modelo de classificação é feita somente em dados reais, e que não foram utilizados durante o treinamento das redes generativas. Isto é feito com o propósito de avaliar a solução em dados que o sistema encontraria durante sua operação.

Todos os resultados mostrados nesta seção correspondem à partição de teste que obteve o melhor índice SP (Soma-Produto) de classificação [138]. O índice SP, definido na equação 6.2, permite uma avaliação equilibrada da performance dos classificadores. Ele é composto dos valores de probabilidade de detecção (P_D) e falso alarme (P_F). Com este índice, é possível determinar o ponto de operação de um classificador que maximiza P_D e minimiza P_F . Para isso, varia-se o limiar do classificador até encontrarmos o valor máximo do índice, que é responsável por colocar o classificador no referido ponto de operação.

$$SP = \sqrt{\sqrt{P_D \times P_F} \times \frac{P_D + P_F}{2}} \quad (6.2)$$

As curvas ROC (*Receiver Operating Characteristic*) [139] também foram usadas como figura de mérito para avaliar o desempenho dos classificadores. A curva ROC também relaciona os valores da probabilidade de detecção e do falso alarme dos classificadores, avaliando diversos patamares (pontos de operação) disponíveis no

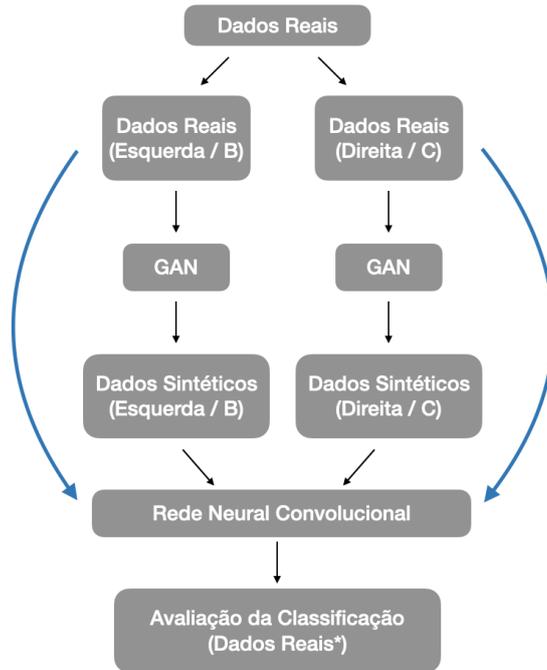


Figura 6.20: Esquema dos pipelines de análise. A seta em azul representa os pipelines de classificação que também usam dados reais em sua composição

classificador. Assim, para avaliar, com uma única medida, o rendimento de diferentes classificadores usamos a área sob a curva ROC (*Area Under the Curve* - AUC), quanto maior for o valor desta medida, maior será a performance do classificador.

Em experimentos de Física de Altas Energias, é comum termos uma medida de eficiência em função de faixas de energia. Isso ocorre pois os processos físicos analisados podem mudar drasticamente de acordo com sua energia. Pensando nisso, este trabalho também avalia a eficiência de classificação, de cada pipeline, em diferentes faixas de ADC coletadas pelo canal onde se encontra a PMT de anodo único. Onde a eficiência é calculada como a fração de eventos que foram classificados corretamente sobre o número total da amostra, para cada faixa de ADC.

Durante o desenvolvimento do trabalho, foram testadas diferentes quantidades de dados sintéticos para alimentar a rede convolutiva. A estatística que obteve o melhor resultado foi de 100 mil eventos para cada classe. Ou seja, nos pipelines apresentados nas seções a seguir temos sempre um total de 200 mil eventos sintéticos, metade para a classe H0 (parte esquerda ou sub-célula B) e outra metade para a classe H1 (parte direita ou sub-célula C). Os resultados mostraram que esse valor de dados sintéticos é suficiente para a etapa de classificação, pois já se encontram acima do número total de parâmetros que a rede deve ajustar durante seu treinamento.

Ao final da análise, todos os resultados são resumidos em tabelas na Seção 6.5, para facilitar a comparação entre os pipelines propostos.

6.4.1 Redes Neurais Convolucionais

Redes Neurais Convolucionais, ou CNNs, nada mais são do que um tipo de rede neural especializado no processamento de dados que possuam uma topologia em grade (*grid*). Por exemplo: dados de séries temporais, podem ser considerados como uma grade 1D que coleta amostra em um intervalo regular de tempo; e dados de imagens podem ser interpretados como uma grade 2D de pixels. Em outras palavras, as CNNs são redes neurais que empregam uma operação matemática chamada convolução, no lugar da multiplicação de matrizes, em pelo menos uma de suas camadas. A arquitetura da rede convolucional usada na etapa de classificação das imagens, pode ser vista na Tabela 6.5.

Tabela 6.5: Arquitetura usada na Rede Convolucional de Classificação.

Camada	Filtros	<i>Kernels</i>	<i>Strides</i>	Função de Ativação
Conv. 2D	32	2	1	ReLU
Conv. 2D	64	2	1	ReLU
Flatten	<i>None</i>	<i>None</i>	<i>None</i>	<i>None</i>
Densa	64	<i>None</i>	<i>None</i>	ReLU
Densa	1	<i>None</i>	<i>None</i>	Sigmóide

As redes convolucionais deste trabalho foram treinadas por até 30 épocas, com bateladas de 128 imagens. A função de Entropia Cruzada foi utilizada para monitorar o conjunto de validação, que corresponde à 10% dos dados de treino. A função de Entropia Cruzada é definida na equação 6.3, onde N é o número de eventos e M é o número de classes do problema. Para evitar *overfitting*, o treinamento da rede foi interrompido caso o erro no conjunto de validação não reduzisse por três épocas seguidas.

$$loss = -\frac{1}{N} \sum_i^N \sum_j^M y_{ij} \log p(y_{ij}) \quad (6.3)$$

6.4.2 Pipeline I - Dados Sintéticos

Neste pipeline utilizamos o conjunto de dados sintéticos para treinar a rede convolucional e avaliamos sua performance nos dados reais, que também não foram utilizados para treinar a rede geradora da GAN. Assim, garantimos que a avaliação do classificador seja feita em dados que o sistema encontrará durante a sua operação.

O objetivo principal deste pipeline é avaliar, na etapa de classificação, o poder preditivo das imagens sintéticas criadas com as redes adversariais generativas. Fornecendo uma nova perspectiva para estudar o comportamento preditivo das imagens sintéticas sendo usadas para detectar um padrão de depósito de energia que ocorreria

em condições reais de operação.

Classificação para a Célula A2

A curva ROC para a classificação do Pipeline I é mostrada na Figura 6.21a. Nela temos o valor médio da curva e sua incerteza estatística calculada através do processo de validação cruzada. O valor de AUC para este pipeline se encontra acima dos 95%, porém a classificação apresenta uma grande flutuação estatística.

As saídas da rede neural podem ser vistas na Figura 6.21b. Esta figura mostra que o algoritmo do Pipeline I não classifica bem os eventos da parte direita da célula para qualquer um dos patamares de classificação disponíveis.

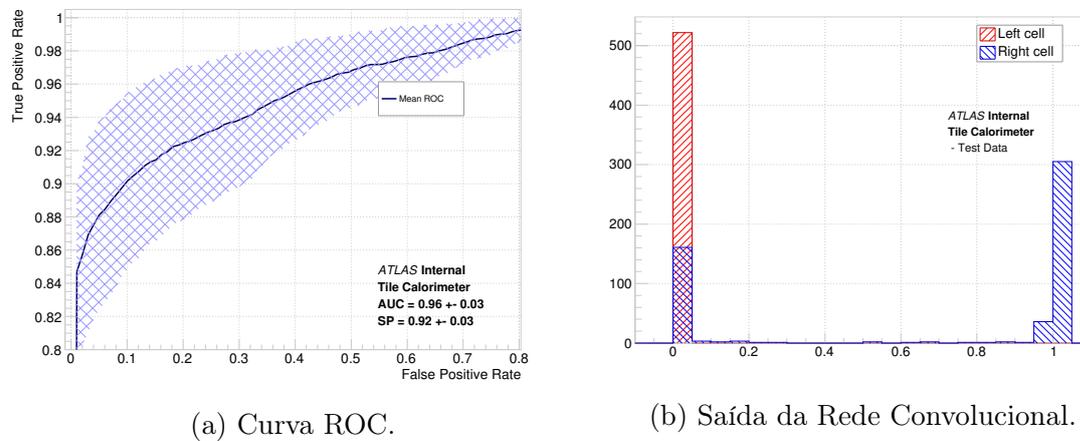
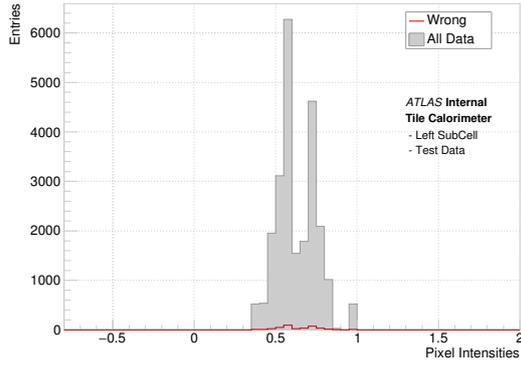


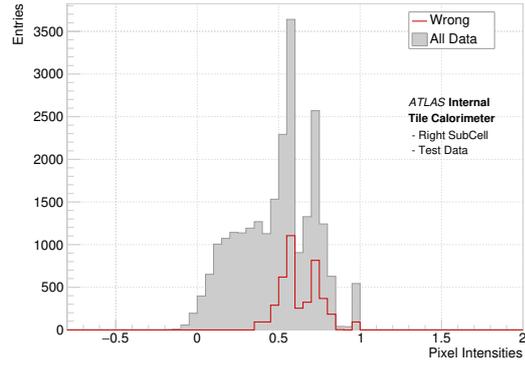
Figura 6.21: Resultados da classificação para a célula A2 no Pipeline I.

A Figura 6.22 mostra as intensidades de pixels, normalizadas pela função de ativação da saída da rede, para a classificação entre as células esquerda e direita da célula A2. Em vermelho vemos as intensidades de pixels para os valores que foram classificados erroneamente. Reafirmamos que este pipeline teve dificuldades para classificar corretamente as imagens que pertenciam à parte direita da célula, com a maior concentração dos erros na região de distribuição bi-modal, mesma faixa onde os dados sintéticos gerados pela GAN não obtiveram uma boa reconstrução, vide Figura 6.14.

A Figura 6.23 mostra a eficiência de classificação do Pipeline I em função de faixas de ADC coletadas pelo canal da PMT de anodo único. Aqui podemos verificar que a eficiência em classificar a parte direita da célula A2 é baixa para as faixas de energias mais altas, visto o resultado dos três últimos *bins* da Figura (b). Confirmando nossa hipótese de que as imagens sintéticas tiveram dificuldade em reconstruir essa faixa de energia, para a sub-célula direita, impactando na sua performance de classificação.

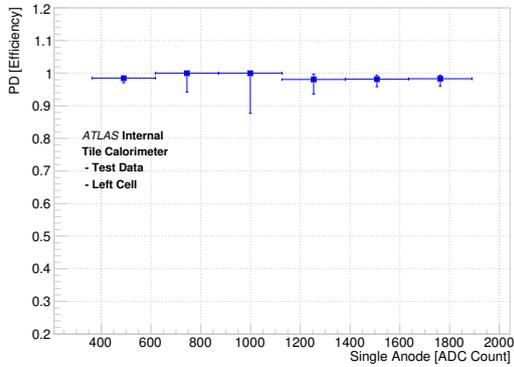


(a) Sub-Célula Esquerda.

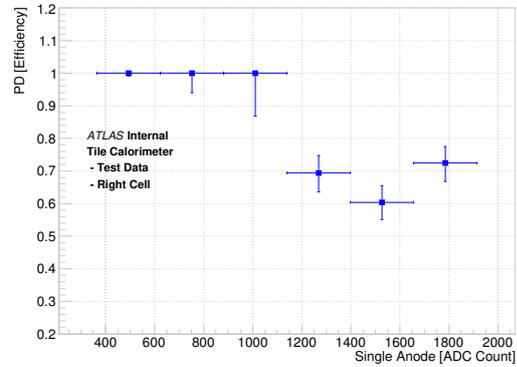


(b) Sub-Célula Direita.

Figura 6.22: Intensidade de pixels das imagens da célula A2 classificadas erroneamente no Pipeline I.



(a) Sub-Célula Esquerda.



(b) Sub-Célula Direita.

Figura 6.23: Eficiência de classificação da célula A2 no Pipeline I.

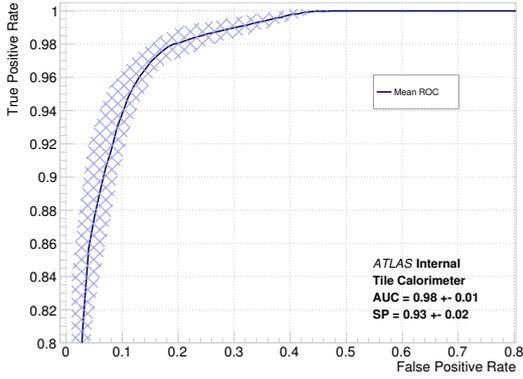
Classificação para a Célula BC1

Aqui vamos avaliar os efeitos do Pipeline I, nas medidas de performance da classificação da célula BC1 em duas novas sub-células, B e C separadamente, que compõe a nova proposta de granularidade longitudinal para a camada BC do TileCal.

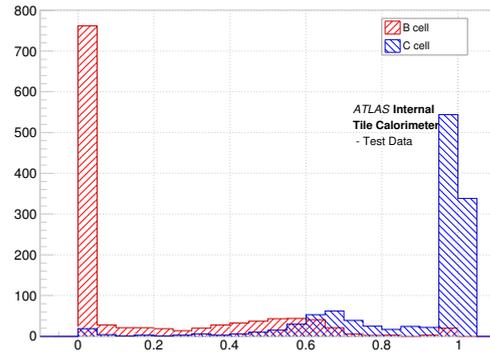
A curva ROC pode ser visualizada na Figura 6.24a e a os valores de saída da redes são mostrados na Figura 6.24b, onde o histograma em vermelho representa os valores para a classe da sub-célula B, enquanto o histograma em azul corresponde aos valores para a classe da sub-célula C.

Nota-se uma boa classificação neste pipeline, apesar de uma região de confusão entre as classes, com uma incerteza estatística menor que os resultados para a célula A2, mostrados anteriormente, representando uma separação mais natural entre as células BC, comparada com a granularidade transversal proposta para as células da camada A.

As Figuras 6.25 e 6.26 são utilizadas para avaliar a faixa de energia, represen-



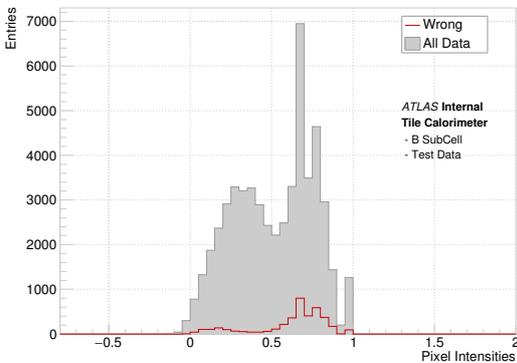
(a) Curva ROC.



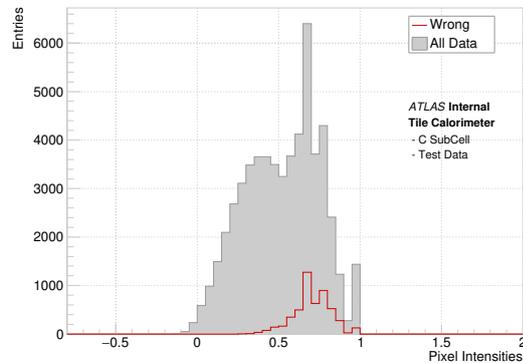
(b) Saída da Rede Convolutacional.

Figura 6.24: Resultados da classificação para a célula BC1 no Pipeline I.

tada aqui como a contagem de ADC, para qual o classificador opera erroneamente; representando a intensidade de pixels e a eficiência de classificação em *bins* de ADC, respectivamente. Podemos notar um comportamento similar ao que ocorre na classificação da célula A2; vemos que as imagens que são classificadas erradamente possuem a maioria de seus pixels concentrados acima da metade da faixa de intensidade. Porém, quando analisamos a eficiência de classificação vemos que a eficiência cai para diversos valores de ADC.



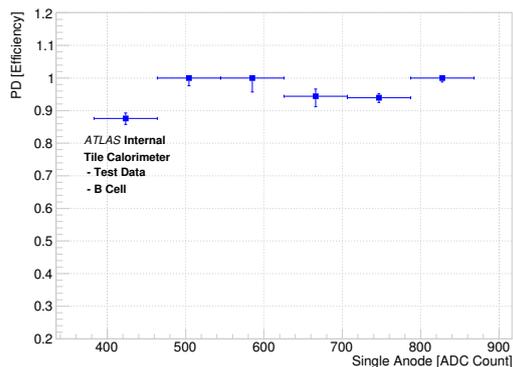
(a) Sub-Célula B.



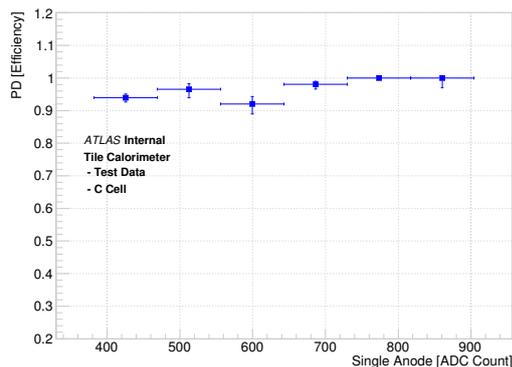
(b) Sub-Célula C

Figura 6.25: Intensidade de pixels das imagens da célula BC1 classificadas erroneamente no Pipeline I.

As Seções 6.4.3 e 6.4.4 visam corrigir os problemas de classificação encontrados no Pipeline I. Nelas, criamos novos pipelines de treinamento que adicionam dados reais à otimização das redes convolucionais. Para facilitar a comparação dos resultados, todas as figuras de mérito utilizadas na análise encontram-se sumarizadas na Seção 6.5.



(a) Sub-Célula B.



(b) Sub-Célula C.

Figura 6.26: Eficiência de classificação da célula BC1 no Pipeline I.

6.4.3 Pipeline II - Dados Sintéticos e Reais

O segundo pipeline analisado no trabalho, visa preencher com dados reais a estatística que não foi bem representada apenas com os dados sintéticos. Para isso, treinamos novamente as redes convolucionais. Porém, agora o conjunto de treinamento das redes consiste em uma junção de dados reais e sintéticos. Ao alimentar a rede neural também com os dados reais, damos a oportunidade do modelo aprender possíveis padrões que não foram contemplados pelas limitações das imagens sintéticas. Como, por exemplo, as regiões de baixa eficiência mostradas na Seção 6.4.2.

Como o número de eventos sintéticos é muito maior que os eventos disponíveis na base de dados reais, devemos garantir que cada batelada de treinamento tenha sempre amostras das duas fontes de dados; garantindo que a proporção de dados reais não seja menor que 10% do total de dados na batelada. Além disso, vale ressaltar que os dados reais, que entram em conjunto neste pipeline, não são os mesmos dados reais que irão avaliar a performance do classificador. Dessa maneira, o Pipeline II utiliza toda a estatística disponível dos dados, sejam eles reais ou sintéticos, para treinar os classificadores neurais que serão aplicados nas novas definições de granularidade das célula A2 e BC1.

Classificação para a Célula A2

A curva ROC para a classificação da célula A2, no Pipeline II, é mostrada na Figura 6.27a. Podemos ver que o novo pipeline de treinamento, utilizando uma combinação de dados reais e sintéticos em cada atualização do modelo, teve um aumento na performance de classificação. Assim como uma pequena redução na incerteza estatística, quando comparada com a Figura 6.21a.

As saídas da rede neural são mostradas na Figura 6.27b, onde também podemos observar que a inserção de dados reais ao processo de treinamento corrigiu o pro-

blema dos alvos da parte direita da célula A2 estarem sobrepostos com as saídas da parte esquerda. Mais um indicativo positivo deste pipeline.

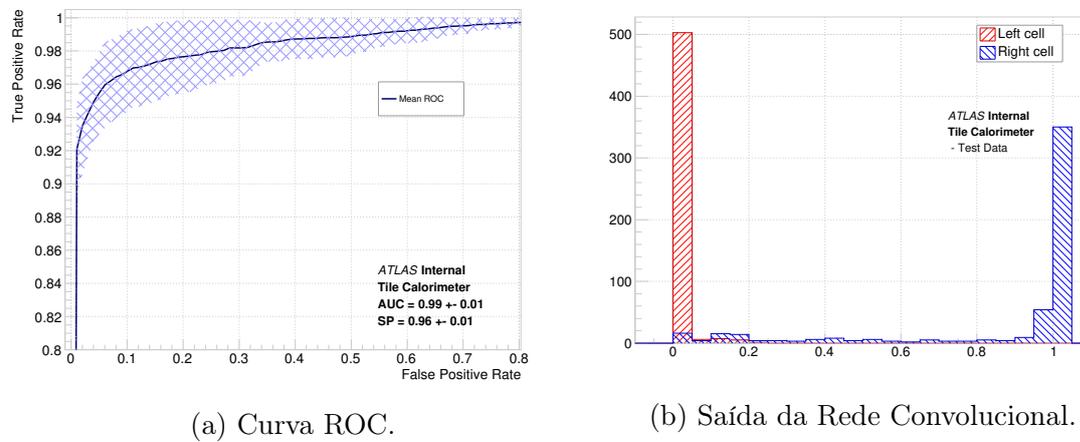


Figura 6.27: Resultados da classificação para a célula A2 no Pipeline II.

As Figuras 6.28 e 6.29 mostram as intensidades de pixels para classificações erradas e a eficiência de classificação para diferentes faixas de ADC, respectivamente. Em ambas as figuras podemos observar que a inserção de dados reais ao treinamento, condição que configura o Pipeline II, foi benéfica pois conseguiu superar o problema da baixa eficiência de classificação da sub-célula direita para altos valores de ADC.

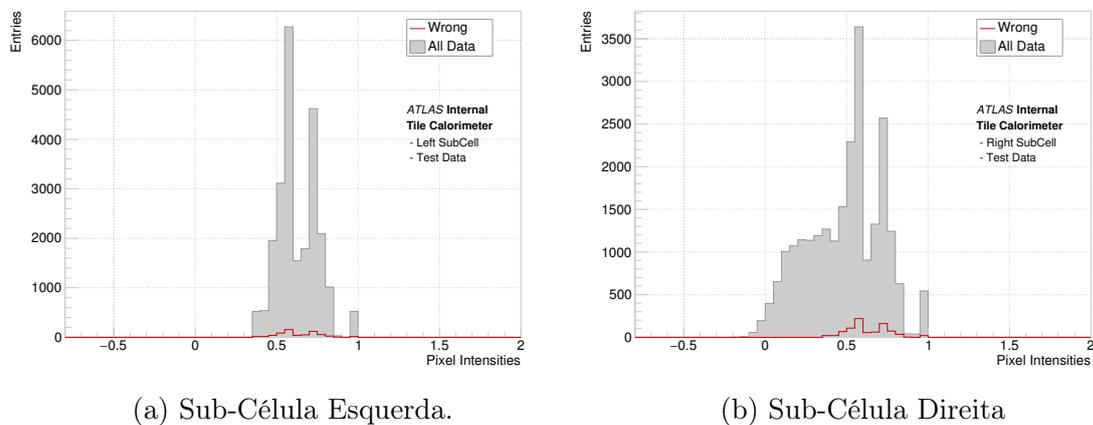
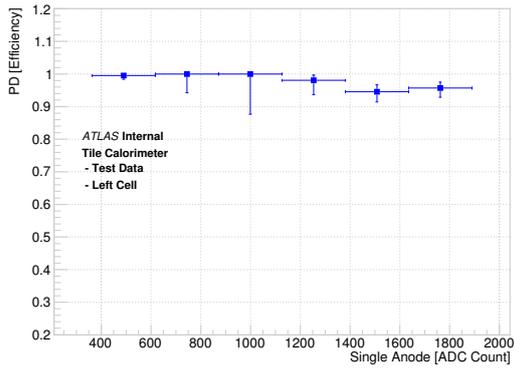


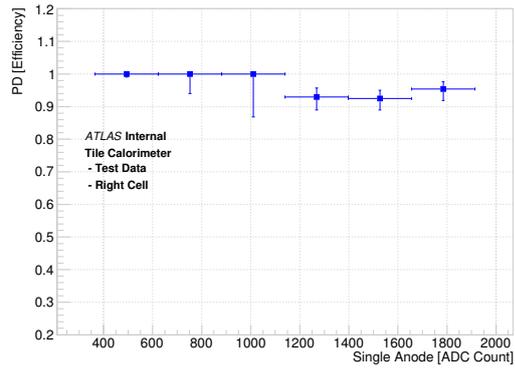
Figura 6.28: Intensidade de pixels das imagens da célula A2 classificadas erroneamente no Pipeline II.

Classificação para a Célula BC1

A curva ROC para a classificação da célula BC1, sob o Pipeline II, é vista na Figura 6.30a. Nela podemos ver com clareza a melhora na classificação da granularidade longitudinal sob este pipeline de treinamento. Tanto o índice SP, quanto a AUC,



(a) Sub-Célula Esquerda.

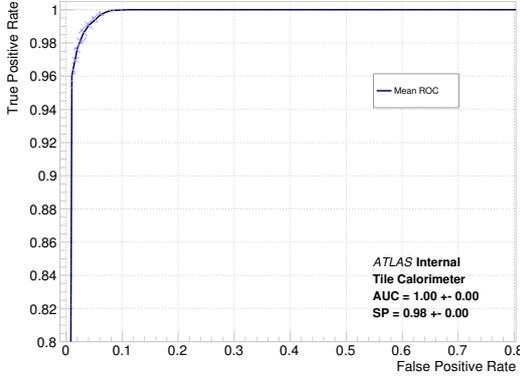


(b) Sub-Célula Direita.

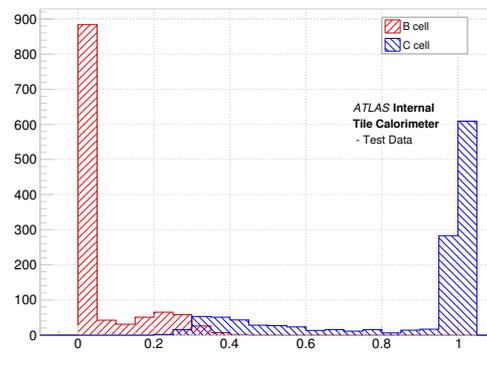
Figura 6.29: Eficiência de classificação da célula A2 no Pipeline II.

passam a ter valores altos, com pouca variabilidade estatística entre as partições de treino.

A Figura 6.30b mostra uma baixa sobreposição entre as classes, com um classificador operando com limiar próximo à 0,3. Assim como na célula A2, este pipeline de treinamento também foi responsável por aumentar as medidas de performance da classificação e reduzir a incerteza estatística do sistema.



(a) Curva ROC.

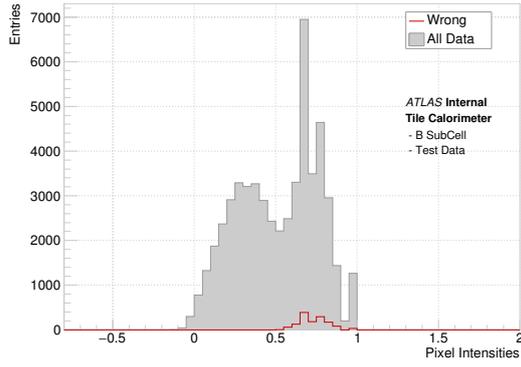


(b) Saída da rede convolucional.

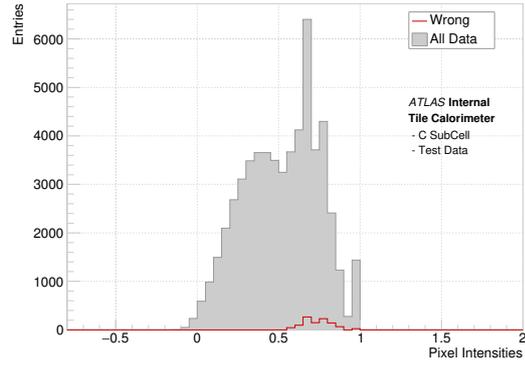
Figura 6.30: Resultados de classificação para a célula BC1 no Pipeline II.

As Figuras 6.31 e 6.32 mostram o restante da análise do Pipeline II. Nelas podemos observar que a adição de dados reais ao treinamento dos classificadores soluciona a baixa eficiência de classificação tanto para a sub-célula B quanto para a sub-célula C. Os bins que apresentavam baixa eficiência, agora apresentam valores máximos quando comparados com os resultados do pipeline anterior, vide Figura 6.26.

Apesar do Pipeline II, apresentar melhorias na classificação da nova granularidade, tanto para a célula A2 quanto para a célula BC1, ainda há um outro modo de testar a combinação de dados reais e sintéticos nos treinamentos das redes con-

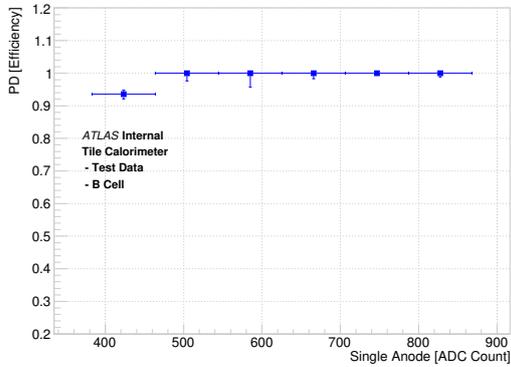


(a) Sub-Célula B.

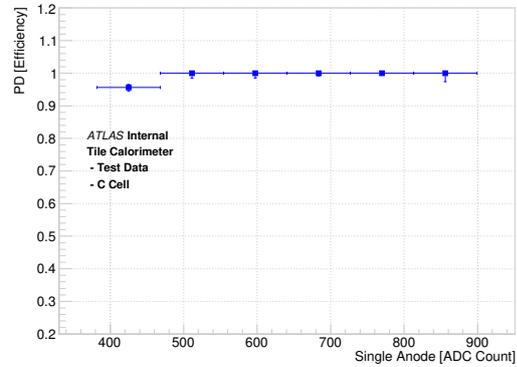


(b) Sub-Célula C

Figura 6.31: Intensidade de pixels das imagens da célula BC1 classificadas erroneamente no Pipeline II.



(a) Sub-Célula B.



(b) Sub-Célula C.

Figura 6.32: Eficiência de classificação da célula BC1 no Pipeline II.

volucionais. Este novo pipeline, assim como seus resultados, é descrito em detalhes na próxima seção.

6.4.4 Pipeline III - Ajuste Fino

O Pipeline III também apresenta uma proposta de treinamento do classificador neural usando uma combinação de dados reais, provenientes da calibração de Césio, e dados sintéticos, gerados pela rede generativa. Porém, este pipeline não fornece dados reais e sintéticos simultaneamente para a rede durante a sua otimização.

Aqui utilizamos as redes treinadas no Pipeline I, somente com os dados sintéticos, e congelamos seus pesos que foram ajustados durante o treinamento. Após isso, realizamos um ajuste fino (*fine tuning*) da rede somente com dados reais. Fazendo com que o algoritmo de classificação seja treinado com amostras reais e sintéticas, porém em etapas diferentes, separadas uma das outras.

Este pipeline permite que a rede possa ajustar seus pesos com dados reais de

forma desacoplada dos dados sintéticos, acessando toda a estatística presente nas amostras. Assim, como no Pipeline II, Seção 6.4.3, os dados reais utilizados na ajuste fino da rede não são os mesmos dados reais que irão avaliar a performance de classificação das novas granularidades.

Classificação para a Célula A2

A curva ROC da classificação da célula A2 no Pipeline III pode ser vista na Figura 6.33a. Nela observamos que a maior contribuição deste pipeline está na redução da incerteza estatística da classificação. Nos resultados desta nova estratégia de treinamento, temos um índice $SP = 96,8 \pm 0,5$. Reduzindo a incerteza de classificação em mais da metade quando comparada ao pipeline anterior.

Para conseguir essa nova classificação, a rede precisou deslocar um pouco os valores de saída da classe H_0 , célula esquerda, como é mostrado na Figura 6.33b. Esse comportamento mostra o efeito do ajuste fino, presente nesse pipeline, em uma das classes do problema.

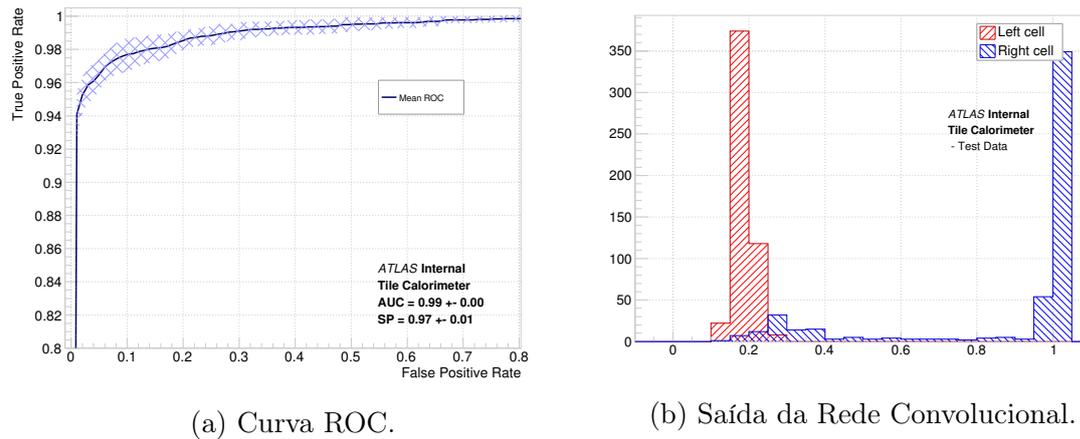
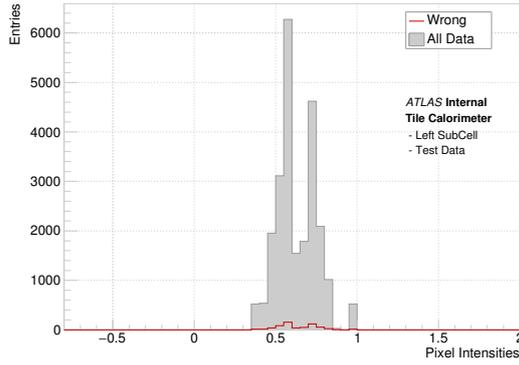


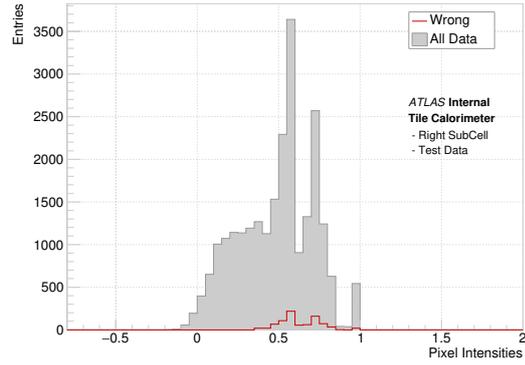
Figura 6.33: Resultados da classificação para a célula A2 no Pipeline III.

Para finalizar a análise da célula A2, as Figuras 6.34 e 6.35 mostram as intensidade dos erros de classificação e a eficiência em função da contagem de ADC, respectivamente. Aqui também podemos observar como o Pipeline III também minimiza o efeito do erro de classificação da sub-célula direita para valores altos de intensidade de pixels e contagem de ADC.

Com isto, vimos que o procedimento de treinamento aplicado no Pipeline III obteve resultados na classificação das imagens da célula A2 com uma medida de $AUC = 99,1 \pm 0,3$, para uma proposta de granularidade que não é tão natural, visto a geometria do detector, quanto a granularidade sugerida nas células da camada BC. Os resultados a seguir mostram como esse pipeline pode impactar ainda mais a classificação longitudinal proposta para as células BC.

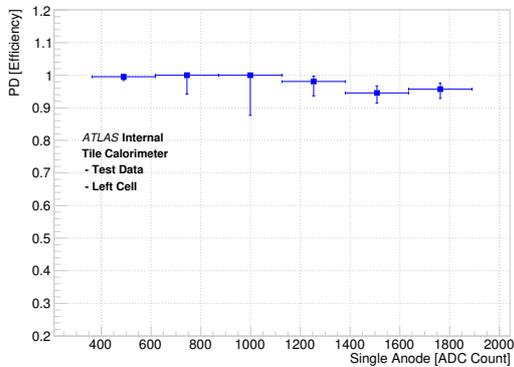


(a) Sub-Célula Esquerda.

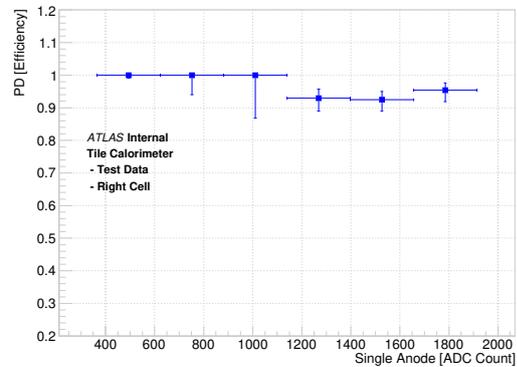


(b) Sub-Célula Direita.

Figura 6.34: Intensidade de pixels das imagens da célula A2 classificadas erroneamente no Pipeline III.



(a) Sub-Célula Esquerda.



(b) Sub-Célula Direita.

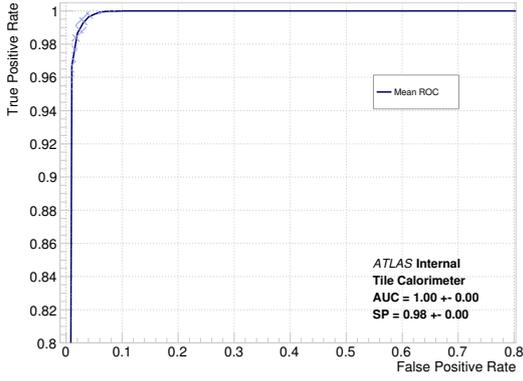
Figura 6.35: Eficiência de classificação da célula A2 no Pipeline III.

Classificação para a Célula BC1

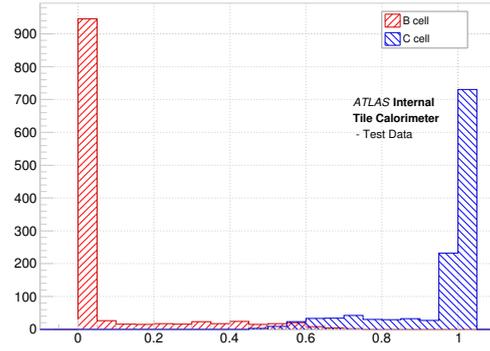
Por último, analisamos os resultados da classificação da célula BC1 sob o Pipeline III, utilizando o conceito de ajuste fino da classificação através de dados reais. As Figuras 6.36a e 6.36b mostram a nova curva ROC e os histogramas de saída da rede convolucional. A nova performance de classificação é representada pelo novo histograma de saída da rede, nele podemos ver que a região que sobrepõe as classes é mínima.

As Figuras 6.37 e 6.38 completam o estudo da classificação da célula BC1 sob este pipeline de treinamento. Especificamente na Figura 6.38 vemos que a eficiência de classificação é máxima em todos os *bins*, para ambas as sub-células, com exceção de um único *bin* correspondente à faixa mais baixa de ADC.

A Seção 6.5 sumariza todos os resultados da fase de classificação, tanto para a célula A2 quanto para a célula BC1, comparando as figuras de mérito utilizadas para avaliar o rendimento dos pipelines propostos neste trabalho.

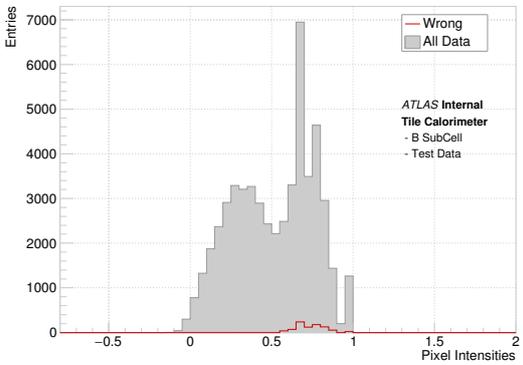


(a) Curva ROC.

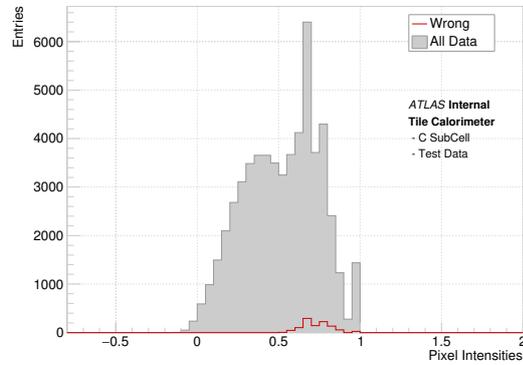


(b) Saída da Rede Convolutacional.

Figura 6.36: Resultados da classificação para a célula BC1 no Pipeline III.



(a) Sub-Célula B.



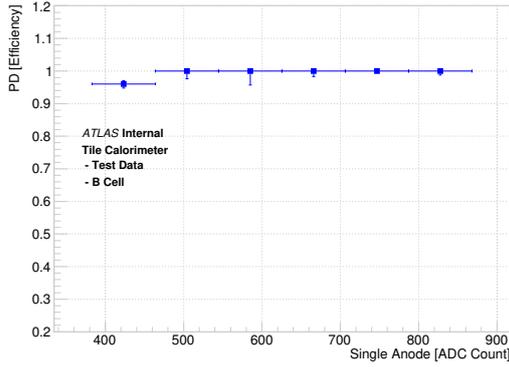
(b) Sub-Célula C

Figura 6.37: Intensidade de pixels das imagens da célula BC1 classificadas erroneamente no Pipeline III.

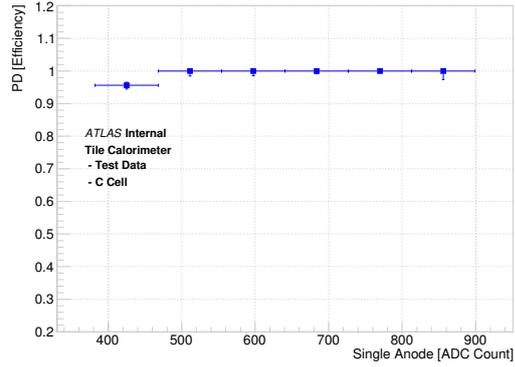
6.5 Resumo da Classificação

A Tabela 6.6 resume os resultados obtidos na classificação da nova granularidade transversal da célula A2, com todos os pipelines propostos neste trabalho. Todos os resultados mostrados na tabela são para os dados reais que permaneceram no conjunto de teste, completamente fora do treinamento do algoritmo.

Vemos um aumento na média das probabilidade de detecção para o Pipeline II, quando passamos a utilizar dados reais em conjunto com os dados sintéticos no treinamento. Este aumento ainda é maior para o Pipeline III, onde utilizamos os dados reais apenas para um ajuste fino da classificação, obtendo assim a maior medida de performance de classificação com a menor incerteza estatística entre os Pipelines. Assim, com a estratégia de dobra a granularidade da célula A2 do TileCal, sem modificar sua estrutura mecânica, temos uma operação de reconhecimento de imagens de suas sub-células com uma medida de $SP = 96,8 \pm 0,5$.



(a) Sub-Célula B.



(b) Sub-Célula C.

Figura 6.38: Eficiência de classificação da célula BC1 no Pipeline III.

Tabela 6.6: Performance de classificação para a célula A2.

	Pipeline I	Pipeline II	Pipeline III
SP	$92,1 \pm 2,0$	$96,1 \pm 1,4$	$96,8 \pm 0,5$
AUC	$95,6 \pm 2,6$	$98,5 \pm 1,1$	$99,1 \pm 0,3$
PD (Sub-Célula Esquerda)	$97,8 \pm 1,2$	$97,8 \pm 0,9$	$98,3 \pm 0,6$
FA (Sub-Célula Esquerda)	$13,5 \pm 5,8$	$5,8 \pm 2,4$	$4,9 \pm 1,1$
PD (Sub-Célula Direita)	$86,5 \pm 5,8$	$94,2 \pm 2,4$	$95,1 \pm 1,1$
FA (Sub-Célula Direita)	$2,2 \pm 1,2$	$2,2 \pm 0,9$	$1,7 \pm 0,6$

Por fim, a Tabela 6.7 sumariza os resultados obtidos na classificação da nova granularidade longitudinal da célula BC1, com todos os pipelines propostos neste trabalho. Assim como na célula A2, todos os resultados mostrados na tabela são para os dados reais que permaneceram no conjunto de teste, completamente fora do treinamento do algoritmo.

Tabela 6.7: Performance de classificação para a célula BC1.

	Pipeline I	Pipeline II	Pipeline III
SP	$92,7 \pm 1,7$	$98,0 \pm 0,3$	$98,5 \pm 0,4$
AUC	$97,8 \pm 0,9$	$99,9 \pm 0,0$	$99,9 \pm 0,0$
PD (Sub-Célula B)	$91,8 \pm 3,4$	$97,7 \pm 0,6$	$98,3 \pm 0,9$
FA (Sub-Célula B)	$6,5 \pm 1,9$	$1,8 \pm 0,7$	$1,4 \pm 0,4$
PD (Sub-Célula C)	$93,5 \pm 1,9$	$98,2 \pm 0,7$	$98,6 \pm 0,4$
FA (Sub-Célula C)	$8,2 \pm 3,4$	$2,3 \pm 0,6$	$1,7 \pm 0,9$

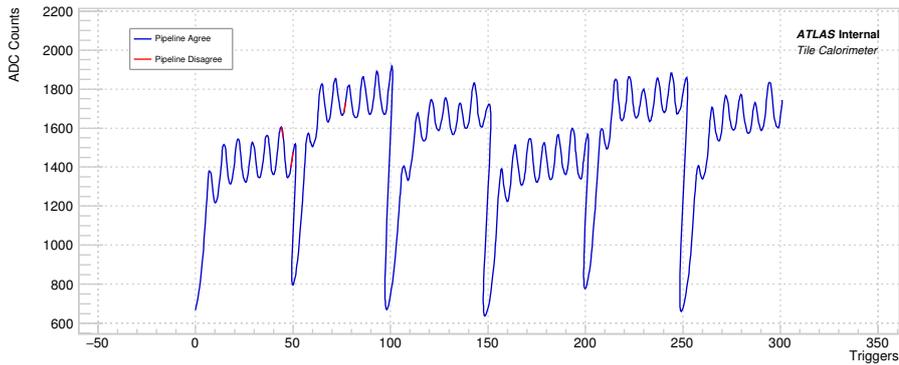
Para a classificação da célula BC1, os Pipelines II e III obtiveram resultados similares, com suas medidas de performance dentro das faixas de incerteza quando comparadas entre si. A superioridade desses pipelines, em detrimento do Pipeline I, são resultados da inserção de dados reais durante o treinamento das redes convolucionais, com o objetivo de fornecer informação sobre a distribuição de probabilidade

que não foi bem contemplada pelas amostras sintéticas.

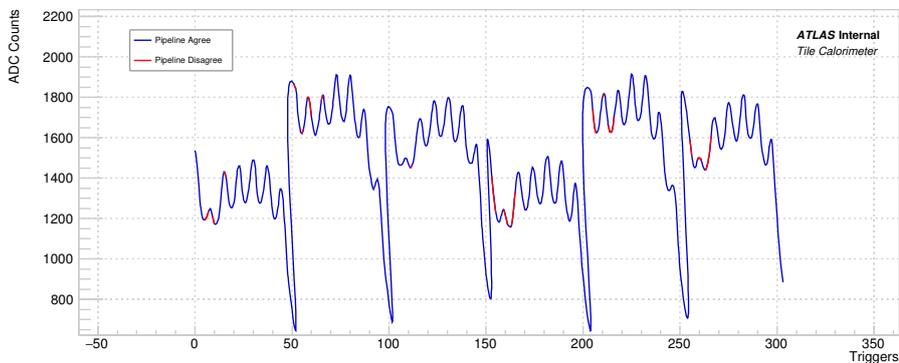
As medidas de performance mais altas para a granularidade longitudinal, devem-se ao fato da divisão das células da camada BC acontecer de maneira mais simples, por conta da proposta original de segmentação do TileCal, onde essas células seriam lidas por PMTs distintas. A proposta mostrada aqui, permite recuperar essa configuração inicial do detector.

Também foi analisado o quanto os pipelines apresentados anteriormente concordam ou discordam entre si, em relação ao seu resultado de classificação. Como tanto para a célula A2 como para a célula BC1, os pipelines que obtiveram resultados de classificação mais discrepantes foram os pipelines I e III, a análise apresentada a seguir se concentra nesses resultados.

A Figura 6.39 mostra a discordância no resultado de classificação para as sub-células esquerda e direita, da célula A2, em função do sinal temporal coletado na PMT de anodo único. Para a célula direita, podemos observar que a discordância entre os pipelines acontece tanto nos dados provenientes da viagem de ida, quanto nos dados coletados na viagem de volta da cápsula de Césio.



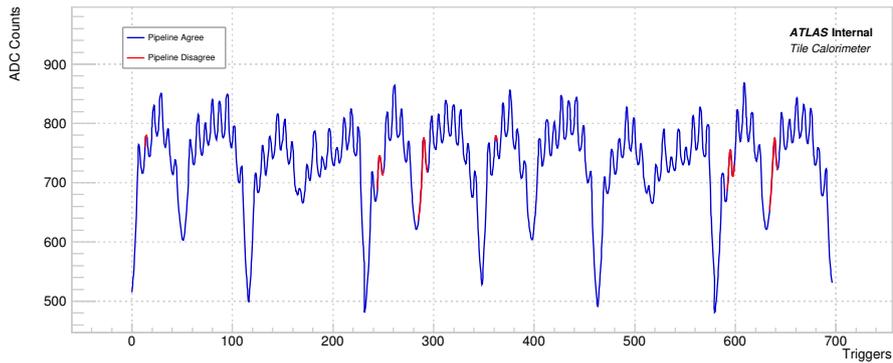
(a) Sub-Célula Esquerda



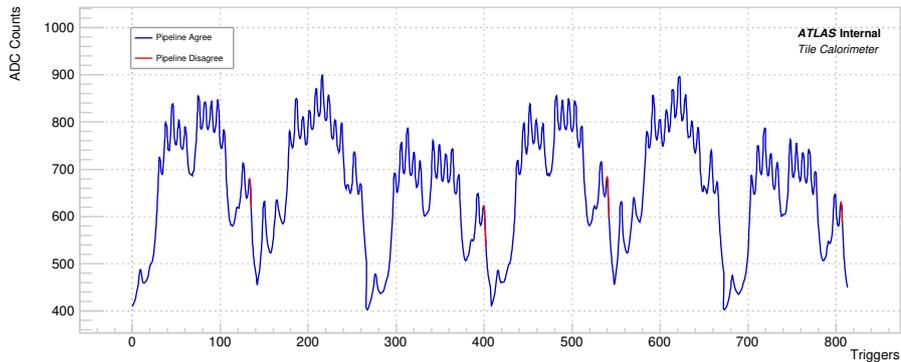
(b) Sub-Célula Direita

Figura 6.39: Concordância (azul) e discordância (vermelho) entre os pipelines I e III para as sub-células Esquerda (a) e Direita (b) da célula A2.

A mesma análise foi aplicada para a célula BC1 e pode ser vista na Figura 6.40. Aqui vemos que as discordâncias entre os pipelines I e III acontecem tanto na ida quanto na volta, para ambas as sub-células B e C. Este comportamento garante a repetibilidade da medição além de dar respaldo para investigações futuras que busquem averiguar quais tipos de imagens fazem com que os classificadores forneçam respostas conflitantes, visto que tal comportamento se repete para todas as outras partições de teste definidas no processo de validação cruzada.



(a) Sub-Célula B



(b) Sub-Célula C

Figura 6.40: Concordância (azul) e discordância (vermelho) entre os pipelines I e III para as sub-células B (a) e C (b) da célula BC1.

Capítulo 7

Conclusões

Jatos de partículas representam grande parte dos objetos físicos detectados pelo experimento ATLAS; aparecem em uma variedade de análises, desde medidas do Modelo Padrão até na procura por Matéria Escura. Sendo assim, medir precisamente estes objetos possui uma importância fundamental para a continuidade do programa de física do LHC; principalmente dentro do contexto do *upgrade* para alta luminosidade (HL-LHC), onde teremos um aumento na taxa de eventos e, consequentemente uma abundância de processos hadrônicos como, por exemplo, o bóson de Higgs decaindo em dois jatos.

Este trabalho apresenta métodos de aperfeiçoamento na medida de energia dos jatos, através de técnicas de processamento de sinais e aprendizado de máquina. As análises apresentadas durante o texto mostram ser possível tornar mais fina a granularidade do calorímetro hadrônico, sem modificar sua estrutura mecânica. Esse processo permite adquirir um aumento na informação espacial de deposição de energia dos jatos de partículas.

Ao fazermos uma modificação na cadeia de leitura do detector, substituindo um canal de leitura que usa uma PMT de anodo único por uma MA-PMT de leitura multi-anodal, foi possível criar um banco de dados anotado de imagens, formadas na grid de 8×8 pixels, que representam regiões específicas dentro da célula do calorímetro. Com isso, a possibilidade de usar algoritmos de *Deep Learning* para classificar esses padrões de imagens foi cogitada, porém a estatística dos dados coletados não se fazia suficiente para ajustar a imensa quantidade de parâmetros desses algoritmos. Para superar este problema, foram criadas Redes Adversariais Generativas com o objetivo de produzir dados sintéticos e aumentar a estatística disponível para treinamento dos classificadores neurais.

As análises de GANs mostraram ser possível criar imagens sintéticas formadas na fotomultiplicadora multianodal, separadas em dois hemisférios dentro da célula, dependendo do tipo de granularidade desejada. Dividindo pela metade a célula A2 e aumentando a informação da deposição espacial de energia dos jatos de partículas,

obtemos uma segmentação transversal da granularidade atual. Enquanto para a célula BC1, foi obtida uma granularidade longitudinal capaz de recuperar a concepção original da estrutura do calorímetro, com duas células distintas B e C.

A etapa de classificação contou com três pipelines de treinamento distintos, dois deles usando uma combinação de dados reais e sintéticos para o treinamento das redes convolucionais. Ao final da análise foi visto que os pipelines que utilizavam dados reais e sintéticos em conjunto obtiveram os melhores resultados, tanto para a granularidade transversal quanto para a longitudinal. O pipeline que utiliza dados reais como um ajuste fino *fine tuning* do classificador obteve índice $SP = 96.8 \pm 0.5$ para dados da célula A2 e $SP = 98.5 \pm 0.4$ para a célula BC1.

Portanto, com contribuições na parte de instrumentação, calorimetria, processamento de sinais e aprendizado de máquina, este trabalho propõe uma nova maneira de tornar mais fina a granularidade do TileCal, possibilitando sua operação no ambiente de *upgrade* pelas próximas décadas. Além disso, os métodos usados neste trabalho também servem de apoio para o estudo de detectores futuros.

Capítulo 8

Trabalhos Futuros

Como trabalhos futuros podemos avaliar o grau de diversidade das imagens sintéticas criadas pelas Redes Generativas. Assim, poderemos medir se as imagens sintéticas são diversas o suficiente para ajudar no processo de classificação ou se elas apenas copiam a distribuição de probabilidade apresentada no conjunto de treinamento do modelo.

O estudo também pode ser estendido para a reconstrução do sinal depositado na célula em questão. A soma da energia depositada nas novas sub-células, separadas com o método aqui proposto, deve ser igual à energia depositada na célula original, antes da separação na nova granularidade. Métodos de processamento de sinais podem ser aplicados com a finalidade de estimar a energia depositada em cada uma dessas células.

Há também a possibilidade de testar uma nova instrumentação com uma PMT de Silício (*Silicon Photomultiplier Tube* - SiPMT) e avaliar as diferenças da metodologia mostrada neste trabalho com uma nova PMT.

Referências Bibliográficas

- [1] NE'EMAN, Y., KIRSH, Y. *The Particle Hunters*. Cambridge University Press, 1996.
- [2] GRIFFITHS, D. *Introduction to Elementary Particles*. Wiley, 2008.
- [3] EDWARDS, D. A., SYPHERS, J. M. *An Introduction to the Physics of High Energy Accelerators*. Wiley, 1992.
- [4] PERKINS, D. H. *Introduction to High Energy Physics*. Cambridge University Press, 2000.
- [5] FEYNMAN, R. *QED the Strange Theory of Light and Matter*. 1990.
- [6] COTTINGHAM, W. N., GREENWOOD, D. A. *An Introduction to the Standard Model of Particle Physics*. 1998.
- [7] KALOS, M. H., WHITLOCK, P. A. *Monte Carlo Methods*. 2008.
- [8] NAGASHIMA, Y. *Beyond the Standard Model of Elementary Particle Physics*. 2014.
- [9] SCERRI, E. “The Evolution of the Periodic System”, *Scientific American*, 1988.
- [10] SEABORG, G. T. “Evolution of the Modern Periodic Table”, *Journal of the Chemical Society, Dalton Transactions*, 1996.
- [11] STANEV, T. *High Energy Cosmic Rays*. 2010.
- [12] HALZEN, F., MARTIN, A. D. *Quarks and Leptons: An Introductory Course in Modern Physics*. 1984.
- [13] GELL-MANN, M. “A Schematic Model of Baryons and Mesons”, *Phys. Lett.*, 1964.
- [14] PARTICLE DATA GROUP. “Review of Particle Physics”, *Chinese Physics C*, 2014.

- [15] THOMSON, J. J. “XL. Cathode Rays”, *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science*, 1897.
- [16] REINES, F., COWAN, C. L. “Detection of the Free Neutrino”, *Phys. Rev.*, 1953.
- [17] NEDDERMEYER, S. H., ANDERSON, C. D. “Note on the Nature of Cosmic-Ray Particles”, *Phys. Rev.*, 1937.
- [18] DANBY, G., GAILLARD, J. M., GOULIANOS, K., et al. “Observation of High Energy Neutrino Reactions and the Existence of Two Kinds of Neutrinos”, *Phys. Rev. Lett.*, 1962.
- [19] PERL, M. L., ABRAMS, G. S., BOYARSKI, A. M., et al. “Evidence for Anomalous Lepton Production in $e^+ - e^-$ Annihilation”, *Phys. Rev. Lett.*, 1975.
- [20] KODAMA, K., USHIDA, N., ANDREOPOULOS, C., et al. “Observation of tau neutrino interactions”, *Physics Letters B*, 2001.
- [21] ATLAS, CDF, CMS AND D0 COLLABORATIONS. “First combination of Tevatron and LHC measurements of the top-quark mass”, 2014.
- [22] BLOOM, E. D., COWARD, D. H., DESTAEBLER, H., et al. “High-Energy Inelastic e p Scattering at 6-Degrees and 10-Degrees”, *Phys. Rev. Lett.*, 1969.
- [23] BREIDENBACH, M., FRIEDMAN, J. I., KENDALL, H. W., et al. “Observed Behavior of Highly Inelastic Electron-Proton Scattering”, *Phys. Rev. Lett.*, 1969.
- [24] AUGUSTIN, J. E., BOYARSKI, A. M., BREIDENBACH, M., et al. “Discovery of a Narrow Resonance in e^+e^- Annihilation”, *Phys. Rev. Lett.*, 1974.
- [25] AUBERT, J. J., BECKER, U., BIGGS, P. J., et al. “Experimental Observation of a Heavy Particle J' ”, *Phys. Rev. Lett.*, 1974.
- [26] CDF COLLABORATION. “Observation of top quark production in $p\bar{p}$ collisions with the Collider Detector at Fermilab”, *Phys. Rev. Lett.*, 1995.
- [27] D0 COLLABORATION. “Observation of the top quark”, *Phys. Rev. Lett.*, 1995.
- [28] HERB, S. W., HOM, D. C., LEDERMAN, L. M., et al. “Observation of a Dimuon Resonance at 9.5 GeV in 400 – GeV Proton-Nucleus Collisions”, *Phys. Rev. Lett.*, 1977.

- [29] GREENBERG, O. W. “Spin and Unitary-Spin Independence in a Paraquark Model of Baryons and Mesons”, *Phys. Rev. Lett.*, 1964.
- [30] VILLARD, P. “Sur la Reflexion et la Refraction des Rayons Cathodiques et des Rayons Deviables du Radium”, *Compt. Ren.*, 1900.
- [31] PLANCK, M. “Ueber das Gesetz der Energieverteilung im Normalspectrum”, *Ann. Phys.*, 1900.
- [32] UA1 COLLABORATION. “Experimental Observation of Isolated Large Transverse Energy Electrons with Associated Missing Energy at $s^{1/2} = 540$ GeV”, *Phys. Lett.*, 1983.
- [33] UA2 COLLABORATION. “Observation of Single Isolated Electrons of High Transverse Momentum in Events with Missing Transverse Energy at the CERN anti-p p Collider”, *Phys. Lett.*, 1983.
- [34] UA1 COLLABORATION. “Experimental Observation of Lepton Pairs of Invariant Mass Around $95 \text{ GeV}/c^2$ at the CERN SPS Collider”, *Phys. Lett.*, 1983.
- [35] UA2 COLLABORATION. “Evidence for $Z^0 \rightarrow e + e^-$ at the CERN anti-p p Collider”, *Phys. Lett.*, 1983.
- [36] PLUTO COLLABORATION. “Evidence for Gluon Bremsstrahlung in $e^+ e^-$ Annihilations at High-Energies”, *Phys. Lett.*, 1979.
- [37] EVANS, L., BRYANT, P. “LHC Machine”, *Journal of Instrumentation - JINST*, v. 3, 2008.
- [38] OHM, C., PAULY, T. “The ATLAS beam pick-up based timing system”, *Nucl. Instrum. Meth.*, 2010.
- [39] LEBRUN, P. “Cryogenics for the Large Hadron Collider”, *IEEE Transactions on Applied Superconductivity*, 2000.
- [40] ATLAS COLLABORATION. “The ATLAS experiment at the CERN LHC”, *Journal of Instrumentation - JINST*, v. 3, 2008.
- [41] CMS COLLABORATION. “The CMS experiment at the CERN LHC”, *Journal of Instrumentation - JINST*, v. 3, 2008.
- [42] ALICE COLLABORATION. “The ALICE experiment at the CERN LHC”, *Journal of Instrumentation - JINST*, v. 3, 2008.

- [43] LHCb COLLABORATION. “The LHCb experiment at the CERN LHC”, *Journal of Instrumentation - JINST*, v. 3, 2008.
- [44] VRETENAR, M. “Radio Frequency for particle accelerators: evolution and anatomy of a technology”. In: *Proceedings, CAS - CERN Accelerator School: RF for Accelerators*, 2012.
- [45] HAFFNER, J. “The CERN accelerator complex”, 2013. Disponível em: <https://cds.cern.ch/record/1621894>. General Photo.
- [46] ROS, E. “ATLAS Inner Detector”, *Nuclear Physics B - Proceedings Supplements*, 2003.
- [47] ATLAS COLLABORATION. “Calorimeter Performance”. In: *Technical Design Report*, 1997.
- [48] PALESTINI, S. “The Muon Spectrometer of the ATLAS Experiment”, *Nuclear Physics B - Proceedings Supplements*, v. 125, 2003.
- [49] ATLAS COLLABORATION. “Observation of a new particle in the search for the Standard Model Higgs boson with the ATLAS detector at the LHC”, *Physics Letters B*, 2012.
- [50] CMS COLLABORATION. “Observation of a new boson at a mass of 125 GeV with the CMS experiment at the LHC”, *Physics Letters B*, 2012.
- [51] CANNONI, M. “Lorentz invariant relative velocity and relativistic binary collisions”, *International Journal of Modern Physics*, v. A 32, 2017.
- [52] ACHENBACH, R., ADRAGNA, P., ANDREI, V., et al. “The ATLAS Level-1 Calorimeter Trigger”, *Journal of Instrumentation*, v. 3, 2008.
- [53] AABOUD, M., AAD, G., ABBOTT, B., et al. “Performance of missing transverse momentum reconstruction with the ATLAS detector using proton–proton collisions at $\sqrt{s} = 13$ TeV”, *The European Physical Journal C*, v. 78, 2018.
- [54] WIGMANS, R. *Calorimetry: Energy Measurement in Particle Physics*. Oxford University Press, 2017.
- [55] WIGMANS, R. “New developments in calorimetric particle detection”, *Progress in Particle and Nuclear Physics*, v. 103, 2018.
- [56] ARIZTIZABAL, F., BOSMAN, M., CAVALLI-SFORZA, M., et al. “Construction and performance of an iron-scintillator hadron calorimeter with

longitudinal tile configuration”, *Nuclear Instruments and Methods*, v. A 349, 1994.

- [57] DAVID, M., GOMES, A., MAIO, A., et al. “15 years of experience with quality control of WLS fibres for the ATLAS Tile Calorimeter”, 2007.
- [58] ABDALLAH, J., ADRAGNA, P., ALEXA, C., et al. “The optical instrumentation of the ATLAS Tile Calorimeter”, *Journal of Instrumentation - JINST*, v. 8, 2013.
- [59] ANDERSON, K. “Design of the front-end analog electronics for the ATLAS tile calorimeter”, *Nucl. Instr. Meth.*, 2005.
- [60] MEYER, C. “The ATLAS Tile Calorimeter Calibration and Performance”, 2013.
- [61] ADRAGNA, P., OTHERS. “Testbeam Studies of Production Modules of the ATLAS Tile Calorimeter”, *Nucl. Instrum. Methods Phys. Res.*, 2009.
- [62] PERALVA, B. *Reconstrução de Energia para Calorímetros Finamente Segmentados*. Tese de doutorado, Universidade Federal de Juiz de Fora, Juiz de Fora, MG, Brasil, 2015.
- [63] SUCCURRO, A. “The ATLAS Tile Hadronic Calorimeter performance in the LHC collision era”, *Physics Procedia*, v. 37, 2012.
- [64] CERN GROUP. “Extended barrels modules 0 installation at CERN”, ATLAS Collection, 1998. Disponível em: <<http://cds.cern.ch/record/40173>>.
- [65] ADRAGNA, P., ANTONAKI, A., BOUDAGOV, I., et al. “A PMT-Block test bench”, *Nucl. Instrum. Meth.*, 2006.
- [66] MARJANOVIC, M. “ATLAS Tile calorimeter calibration and monitoring systems”, *ArXiv e-prints*, 2018.
- [67] STARCHENKO, E. “Cesium Monitoring System for the ATLAS Tile Hadron Calorimeter”, *Nucl. Instr. Meth.*, 2002.
- [68] KLIMEK, P. “Performance of the ATLAS Tile Calorimeter in LHC Run-2”, *JINST*, 2019.
- [69] ABDALLAH, J. “The Laser calibration of the ATLAS Tile Calorimeter during the LHC run 1”, *Journal of Instrumentation*, 2016.

- [70] THE ATLAS COLLABORATION. “Public Tile Calorimeter Plots for Collision Data”, 2020. Disponível em: <<http://cds.cern.ch/record/40173>>.
- [71] ATLAS COLLABORATION. “ATLAS tile calorimeter: Technical Design Report”, 1996.
- [72] ROSSETTI, V. “Commissioning of the ATLAS Tile Hadronic Calorimeter with cosmic muons, single beams and first collisions”, 2010.
- [73] ADRAGNA, P., OTHERS. “Testbeam studies of production modules of the ATLAS Tile Calorimeter”, *Nuclear Instruments and Methods*, v. A 606, 2009.
- [74] AAD, G., OTHERS. “Readiness of the ATLAS Tile Calorimeter for LHC collisions”, *EPJC Particles and Fields*, v. 70, 2010.
- [75] APOLLINARI, G., BRÜNING, O., NAKAMOTO, T., et al. “High Luminosity Large Hadron Collider HL-LHC”, *CERN Yellow Report*, 2015.
- [76] MELIS, C. D. “Timeline for the LHC and High-Luminosity LHC”, General Photo, 2015. Disponível em: <<https://cds.cern.ch/record/2063307>>.
- [77] GOTTFRIED, K., WEISSKOPF, V. *Concepts of Particle Physics*. United Kingdom, Clarendon Press, 1986.
- [78] CAMPAGNARI, C., FRANKLIN, M. “The Discovery of the Top Quark”, *Rev. Mod. Phys.*, 1997.
- [79] CAMARDA, S. “W/Z+Jets and W/Z+HF Production at the Tevatron”. In: *Proceedings, 48th Rencontres de Moriond on QCD and High Energy Interactions*, 2013.
- [80] ATLAS COLLABORATION. “Search for the Standard Model Higgs boson decaying into $b\bar{b}$ produced in association with top quarks decaying hadronically in pp collisions at $\sqrt{s} = 8$ TeV with the ATLAS detector”, *JHEP*, 2016.
- [81] RANGEL, M. “Experimental aspects of jet physics at LHC”. In: *Proceedings, New Trends in High-Energy Physics and QCD: Natal, Rio Grande do Norte, Brazil*, 2016.
- [82] SJÖSTRAND, T., ASK, S., CHRISTIANSEN, J. R., et al. “An Introduction to PYTHIA 8.2”, *Comput. Phys. Commun.*, 2015.

- [83] CORCELLA, G., OTHERS. “HERWIG 6.5: an event generator for Hadron Emission Reactions With Interfering Gluons (including supersymmetric processes)”, *JHEP*, 2001.
- [84] MANGANO, M. L., MORETTI, M., PICCININI, F., et al. “ALPGEN, a generator for hard multiparton processes in hadronic collisions”, *JHEP*, 2003.
- [85] OLELARI, C. “The POWEG Box”, *Nucl. Phys. Proc. Suppl.*, 2010.
- [86] AGOSTINELLI, S., ALLISON, J., AMAKO, K., et al. “Geant4 - a simulation toolkit”, *Nucl. Instr. Meth. Phys. A*, 2003.
- [87] LAMPL, W., LAPLACE, S., LELAS, D., et al. “Calorimeter Clustering Algorithms: Description and Performance”, 2008.
- [88] CACCIARI, M., SALAM, G. P., SOYEZ, G. “The anti- k_t jet clustering algorithm”, *JHEP*, 2008.
- [89] CACCIARI, M., SALAM, G. P., SOYEZ, G. “FastJet User Manual”, *Eur. Phys. J.*, 2012.
- [90] ATLAS COLLABORATION. “Technical Design Report for Phase-II Upgrade of the ATLAS Tile Calorimeter”, 2017.
- [91] ROBINSON, J. E. *Jet physics with the ATLAS experiment at the LHC*. Ph.D. thesis, University College London, London, United Kingdom, 2012.
- [92] SJOSTRAND, T., MRENNNA, S., SKANDS, P. Z. “PYTHIA 6.4 Physics and Manual”, *Journal of High Energy Physics - JHEP*, v. 05, 2006.
- [93] KRIVKOVA, P., LEITNER, R. *Measurement of the Interaction Length of Pions and Protons in the TileCal Module 0*. Relatório Técnico ATL-TILECAL-99-007, CERN, 1999.
- [94] KULCHITSKY, Y. A., OTHERS. “Study of the Hadron Shower Profiles with the ATLAS Tile Hadron Calorimeter”, *ArXiv High Energy Physics - Experiment e-prints*, 1999.
- [95] CHEKANOV, S. V., BEYDLER, M., KOTWAL, A. V., et al. “Initial Performance Studies of a General-Purpose Detector for Multi-TeV Physics at a 100 TeV pp Collider”, *Journal of Instrumentation - JINST*, v. 12, 2017.
- [96] CHEKANOV, S., NGUYEN, D. H., PROUDFOOT, J. *Monte Carlo Simulation of High- p_T Jets in Tile Calorimeter*. Relatório Técnico ATL-COM-TILECAL-2015-057, CERN, 2015.

- [97] LUNDBERG, O. *Searches for Dark Matter and Large Extra Dimensions in Monojet Final States with the ATLAS Experiment*. Ph.D. thesis, Stockholm University, Stockholm, Sweden, 2016.
- [98] CHEKANOV, S. V., DULL, J. “Energy Range of Hadronic Calorimeter Towers and Cells for High-pT Jets at a 100 TeV Collider”, *ArXiv e-prints*, 2015.
- [99] MILLER, D. “Jet substructure in ATLAS”, *ArXiv e-prints*, 2011.
- [100] RANGEL, M. “Experimental aspects of jet physics at LHC”, *ArXiv e-prints*, 2016.
- [101] ATLAS COLLABORATION. “Performance of Jet Substructure Techniques for Large-R Jets in Proton-Proton Collisions at $\sqrt{s} = 7$ TeV Using the ATLAS Detector”, *ArXiv e-prints*, 2013.
- [102] CALKINS, R., CHEKANOV, S., CONWAY, J., et al. “Reconstructing top quarks at the upgraded LHC and at future accelerators”. In: *Proceedings, 2013 Community Summer Study on the Future of U.S. Particle Physics: Snowmass on the Mississippi*, 2013.
- [103] ATLAS COLLABORATION. “Performance of large-R jets and jet substructure reconstruction with the ATLAS detector”, 2012.
- [104] ATLAS COLLABORATION. “Technical Design Report for the Phase-II Upgrade of the ATLAS Tile Calorimeter”, 2017.
- [105] MOSES, W. “Photodetectors for Nuclear Medical Imaging”, *Nuclear Instruments and Methods*, v. A 610, 2009.
- [106] HERBERT, D., MOEHRS, S., DAASCENZO, N., et al. “The Silicon Photomultiplier for Application to High-Resolution Positron Emission Tomography”, *Nuclear Instruments and Methods*, v. A 573, 2007.
- [107] GUEDES, L., MASSAFFERRI, A. *Projeto e Desenvolvimento de Eletrônica de Front-End para Detectores a Base de MaPMT*. Relatório Técnico CBPF-NT-008/17, Centro Brasileiro de Pesquisas Físicas - CBPF, 2017.
- [108] AKGUN, U., OTHERS. “Characterization of 1800 Hamamatsu R7600-M4 PMTs for CMS HF Calorimeter Upgrade”, *Journal of Instrumentation - JINST*, v. 9, 2014.
- [109] TIRAS, E., BILKI, B., ONEL, Y. “Commissioning of CMS Forward Hadron Calorimeters with Upgraded Multi-anode PMTs and TCA Readout”, *Proceedings of Science - PoS*, v. ICHEP 2016, 2017.

- [110] AJALTOUNI, Z., OTHERS. “Study of multianode photomultipliers for the electromagnetic calorimeter preshower read out of the LHCb experiment”, *Nuclear Instruments and Methods*, v. A 504, 2003.
- [111] CARLOGANU, C. “MAPMTs and FE Electronics for the LHCb Preshower Readout”, *Nuclear Instruments and Methods*, v. A 518, 2004.
- [112] HAMAMATSU PHOTONICS. *Multianode Photomultiplier Tube Assembly H7546A, H7546B*. Relatório Técnico TPMH1240E12, Hamamatsu, 2007.
- [113] STROBBE, N. “The Upgrade of the CMS Hadron Calorimeter with Silicon Photomultipliers”, *Journal of Instrumentation - JINST*, v. 12, 2017.
- [114] XU, Z., HAEFELI, G. “Silicon Photomultipliers for the LHCb Upgrade Scintillating Fibre Tracker”, *Proceedings of Science - PoS*, v. TIPP 2014, 2014.
- [115] LECUN, Y., HAFFNER, P., BOTTOU, L., et al. “Object Recognition with Gradient-Based Learning”. In: *Shape, Contour and Grouping in Computer Vision*, 1999.
- [116] HE, K., ZHANG, X., REN, S., et al. “Delving deep into rectifiers: Surpassing human-level performance on imagenet classification”. In: *International Conference on Computer Vision*, 2015.
- [117] REDMON, J., DIVVALA, S., GIRSHICK, R., et al. “You only look once: Unified, real-time object detection”. In: *International Conference on Computer Vision and Pattern Recognition*, 2016.
- [118] LONG, J., SHELHAMER, E., DARRELL, T. “Fully convolutional networks for semantic segmentation”. In: *International Conference on Computer Vision and Pattern Recognition*, 2015.
- [119] BRIGATO, L., IOCCHI, L. “A Close Look at Deep Learning with Small Data”. In: *International Conference on Computer Vision and Pattern Recognition*, 2020.
- [120] GOODFELLOW, J., BENGIO, Y. “Generative Adversarial Networks”, *ArXiv e-prints*, 2014.
- [121] SHALANDA, N., KARYUKHIN, A., KOPIKOV, S., et al. “Radioactive source control and electronics for the ATLAS tile calorimeter cesium calibration system”, *Nucl. Instr. Meth.*, 2003.
- [122] HORN, T., ROBERTS, C. D. “The pion: an enigma within the Standard Model”, *Journal of Physics G: Nuclear and Particle Physics*, 2016.

- [123] PEREIRA, R. *Estimação de Energia em um Calorímetro Finamente Segmentado*. Tese de doutorado, Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ, Brasil, 2014.
- [124] HASTIE, T., TIBSHIRANI, R., FRIEDMAN, J. *The Elements of Statistical Learning*. Springer, 2009.
- [125] JAMES, G., WITTEN, D., HASTIE, T., et al. *An Introduction to Statistical Learning*. Springer, 2013.
- [126] BREIMAN, L., SPECTOR, P. “Submodel Selection and Evaluation in Regression: The X-random case”, *International Statistical Review*, 1992.
- [127] GOODFELLOW, I., POUGET-ABADIE, J., MIRZA, M., et al. “Generative Adversarial Nets”. In: *Advances in Neural Information Processing Systems*, 2014.
- [128] RADFORD, A., METZ, L., CHINTALA, S. “Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks”. In: *International Conference on Learning Representations*, 2016.
- [129] PAGANINI, M., OLIVEIRA, L., NACHMAN, B. “CaloGAN: Simulating 3D High Energy Particle Showers in Multi-Layer Electromagnetic Calorimeters with Generative Adversarial Networks”, *Phys. Rev. D*, 2018.
- [130] MUSTAFA, M., BARD, D., BHIMIJI, W., et al. “CosmoGAN: creating high-fidelity weak lensing convergence maps using Generative Adversarial Networks”, *Computational Astrophysics and Cosmology*, 2019.
- [131] HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. Upper Saddle River, NJ, Prentice Hall, 1998.
- [132] NAIR, V., HINTON, G. “Rectified Linear Units Improve Restricted Boltzmann Machines”. In: *International Conference on Machine Learning*, 2010.
- [133] MASS, A. L., HANNUN, A., NG, A. Y. “Rectifier Nonlinearities Improve Neural Network Acoustic Models”. In: *International Conference on Machine Learning*, 2013.
- [134] DIEDERIK, P., BA, J. “Adam: A Method for Stochastic Optimization”. In: *International Conference for Learning Representations*, 2015.

- [135] AROHAN, A., KOUSTAV, A., ABHISHEK, S. “A Review of Convolutional Neural Networks”. In: *International Conference on Emerging Trends in Information Technology and Engineering*, 2020.
- [136] AZEDDINE, E., FLORENTIN, S. “Trends in deep convolutional neural Networks architectures: a review”. In: *International Conference of Computer Science and Renewable Energies*, 2019.
- [137] GU, J., WANG, Z., KUEN, J., et al. “Recent advances in convolutional neural networks”, *Pattern Recognition*, 2018.
- [138] ANJOS, A., TORRES, R., SEIXAS, J. M. “Neural Triggering System Operating on High Resolution Calorimetry Information”. In: *Advanced Computing and Analysis Techniques*, 2006.
- [139] VAN-TREES, H. *Detection Estimation and Modulation Theory*. John Wiley and Sons, 2001.

Apêndice A

Projeto de *Authorship* do ATLAS

O processo de *authorship* trata-se do período que o proponente (o autor desta tese) passa por diversas avaliações para se tornar membro da colaboração ATLAS e, conseqüentemente, autor dos seus artigos. O projeto consiste na definição de um tema de real importância para o experimento e geralmente possui duração de um ano. O acompanhamento é dado por dois supervisores, um local, da própria instituição de ensino, e um supervisor geral, membro do ATLAS. Durante esse período, diversas apresentações são realizadas, pelo proponente, em reuniões da colaboração. Abaixo encontra-se o resumo aprovado do projeto.

- **Responsible:** Oleg Solovyanov
- **Description:** This project concerns to study the possibility to obtain a thinner cell granularity in the Tile Calorimeter using a photomultiplier tube with multi-anode reading capability (MA-PMT). In order to check for a better calorimeter granularity, pattern recognition and other efficient types of algorithms will be applied as an alternative method to associate the images produced by the MA-PMT pixels into divided sub-cells regions.
- **Local Supervisor:** Jose Seixas
- **Technical Supervisor:** Oleg Solovyanov
- **Beginning of Qualification:** 2018/06/01
- **Qualification Date:** 2019/06/01

Apêndice B

Produção Científica

Produção científica que se relacionam ao trabalho apresentado nesta tese.

1. GASPAR, P., SEIXAS J.M. "Towards the Increase in Granularity for the Main Hadronic ATLAS Calorimeter: Exploiting Deep Learning Methods", *Journal of Physics: Conference Series*, 2020
2. AABOUD, M., AAD, G., GASPAR, P., et al. "Performance of electron and photon triggers in ATLAS during LHC Run 2", *The European Physical Journal C*, 2020
3. GASPAR, P., SEIXAS J.M. "Aprendizado Profundo para Tornar Mais Fina a Granularidade do TileCal", *Encontro Nacional de Física de Partículas e Campos*, 2021
4. GASPAR, P., SEIXAS J.M. "Leitura Multi-Anodal - Usando uma Fotomultiplicadora Multi-Anodo para Tornar Mais Fina a Granularidade do Calorímetro Hadrônico TileCal do ATLAS", *Rede Nacional de Física de Altas Energias*, 2021