



APRENDIZADO PROFUNDO PARA FILTRAGEM ONLINE NUMA REGIÃO
DE BAIXA RESOLUÇÃO DE UM CALORÍMETRO FINAMENTE
SEGMENTADO

Isabella Silva Ferreira

Dissertação de Mestrado 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 Mestre em Engenharia Elétrica.

Orientadores: José Manoel de Seixas
Marcia Begalli

Rio de Janeiro
Outubro de 2022

APRENDIZADO PROFUNDO PARA FILTRAGEM ONLINE NUMA REGIÃO
DE BAIXA RESOLUÇÃO DE UM CALORÍMETRO FINAMENTE
SEGMENTADO

Isabella Silva Ferreira

DISSERTAÇÃO 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 MESTRE EM CIÊNCIAS EM ENGENHARIA ELÉTRICA.

Orientadores: José Manoel de Seixas
Marcia Begalli

Aprovada por: Prof. Helena Brandão Malbouisson
Prof. José Gabriel Rodriguez Carneiro Gomes
Prof. Renato Tinós

RIO DE JANEIRO, RJ – BRASIL
OUTUBRO DE 2022

Silva Ferreira, Isabella

Aprendizado profundo para filtragem online numa região de baixa resolução de um calorímetro finamente segmentado/Isabella Silva Ferreira. – Rio de Janeiro: UFRJ/COPPE, 2022.

XVI, 90 p.: il.; 29, 7cm.

Orientadores: José Manoel de Seixas

Marcia Begalli

Dissertação (mestrado) – UFRJ/COPPE/Programa de Engenharia Elétrica, 2022.

Referências Bibliográficas: p. 75 – 84.

1. Sistema de Filtragem Online.
 2. Redes Neurais.
 3. Classificação.
 4. Deep Learning.
 5. Física de Altas Energias.
- I. Seixas, José Manoel de *et al.*
II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Elétrica. III. Título.

*Para os meus pais e meu
companheiro Micael Veríssimo.
Obrigada pelo apoio e paciência.*

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

APRENDIZADO PROFUNDO PARA FILTRAGEM ONLINE NUMA REGIÃO
DE BAIXA RESOLUÇÃO DE UM CALORÍMETRO FINAMENTE
SEGMENTADO

Isabella Silva Ferreira

Outubro/2022

Orientadores: José Manoel de Seixas

Marcia Begalli

Programa: Engenharia Elétrica

O ATLAS é um dos experimentos do LHC, o maior acelerador de partículas do mundo, localizado no CERN. Colisões são produzidas pelo LHC a cada 25 ns e atingiram 13 TeV de energia em 2018. Nesse ambiente de alta taxa de eventos (cerca de 60 TB/s), um sistema de filtragem *online* (*Trigger*) é mandatório para selecionar quais eventos devem ser armazenados. O experimento ATLAS adotou o algoritmo *NeuralRinger* na etapa rápida do segundo nível do *Trigger* de elétrons a partir de 2017. Este algoritmo compacta a informação do sistema de calorimetria através da construção de anéis concêntricos ao redor da célula mais energética do chuveiro. Estes anéis são usados como entradas em uma *ensemble* de redes neurais especialistas onde cada uma delas atua de acordo com a posição da partícula no calorímetro e sua energia. Atualmente o *Trigger* de elétrons é projetado para operar somente na região central do detector ($\eta < 2,5$), não contemplando a região *Forward* ($\eta > 2,5$). Todavia muitos processos físicos de interesse possuem elétrons em seus estados finais que são produzidos em ângulos menores do que 10° em relação ao feixe de partículas e a seleção online destes elétrons auxiliaria no estudo de tais processos, uma vez que isto reduziria a perda de eventos com física de interesse. Desta forma, este trabalho busca estender a atuação do *NeuralRinger* para região *Forward* do calorímetro mediante a emulação das características dessa região e a partir de dados da área mais externa coberta pelo *Trigger*. Modelos baseados em MLP e redes neurais convolucionais foram treinados usando dados de colisão e seu desempenho foi comparado com objetivo de avaliar a eficiência na detecção de elétrons e se o modelo profundo teria desempenho superior nesta etapa de filtragem.

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

DEEP LEARNING FOR ONLINE FILTERING IN A LOW-RESOLUTION
REGION OF A THIN SEGMENTED CALORIMETER

Isabella Silva Ferreira

October/2022

Advisors: José Manoel de Seixas

Marcia Begalli

Department: Electrical Engineering

The ATLAS is one of the experiments at LHC, the world's largest particle accelerator, located at CERN. Collisions are produced by the LHC every 25 ns and reached around 13 TeV of energy in 2018. In this high event rate environment (about 60 TB/s), an online filtering system is mandatory to select which events will be stored. The ATLAS experiment adopted the NeuralRinger algorithm in the Fast step of the second level of the Electron Trigger in 2017. This algorithm compresses the calorimetry system information by building concentric rings around the most energetic cell of shower. These rings are entries in an ensemble of expert neural networks where each of them acts according to the position in the calorimeter and the particle energy. Currently, the online electron filtering system is developed to operate only in the central region of the detector ($\eta < 2.5$), not including the Forward region ($\eta > 2.5$). However, many physical processes of interest have high pseudorapidity electrons in their final states produced at angles smaller than 10° relative to the particle beam. The online selection of these electrons would help to study these processes, as it reduces the loss of events with the physics of interest. Therefore, this work investigates extending the performance of the NeuralRinger to the Forward calorimeter region by emulating the characteristics of this region from data of the outermost area covered by the Trigger. Models based on MLP and convolutional neural networks were trained using collision data to compare their efficiency in electron detection and check if a deep learning model would have a superior performance in the filtering task.

Sumário

Lista de Figuras	ix
Lista de Tabelas	xi
Lista de Símbolos	xii
Lista de Abreviaturas	xiv
1 Introdução	1
1.1 Motivação	2
1.2 Objetivos	4
1.3 Organização da dissertação	5
2 A física experimental e de altas energias e o LHC	6
2.1 As partículas elementares e o Modelo Padrão	6
2.1.1 Interação das partículas com a matéria	8
2.1.2 Física de interesse nas regiões de alta pseudorapidez do detector	9
2.2 Large Hadron Collider (LHC)	10
2.3 Inteligência computacional em física de altas energias	10
3 O Experimento ATLAS	13
3.1 Sistema de Coordenadas do ATLAS	14
3.2 Detector Interno	14
3.2.1 O Detector de Pixel	15
3.2.2 SCT	15
3.2.3 TRT	15
3.3 Sistema de Calorimetria	16
3.3.1 Calorímetro Eletromagnético	18
3.3.2 Calorímetro Hadrônico	18
3.3.3 Calorímetro Dianteiro (FCAL)	19
3.4 Sistema de Trigger	21

4	Sistema de Filtragem Online de Elétrons do ATLAS	24
4.1	<i>L1Calo</i>	25
4.2	HLT	26
4.2.1	Reconstrução rápida do calorímetro e etapa de pré-seleção	27
4.2.1.1	<i>CutBased</i>	29
4.2.1.2	<i>NeuralRinger</i>	29
4.2.1.2.1	Informação anelada de calorimetria	29
4.2.1.2.2	Método de filtragem <i>online</i> de elétrons	30
4.2.2	Reconstrução rápida do traço e seleção de elétrons	32
4.2.3	Etapa precisa do HLT	33
4.3	Estratégias de identificação de elétrons para regiões de alta pseudo-rapidez	36
5	Método	41
5.1	Seleção de Amostras e Redução Sintética de Granularidade	41
5.2	Modelos Utilizados	43
5.2.1	Ajuste em Função de $\langle\mu\rangle$	46
5.3	Seleção e Avaliação dos Modelos	47
6	Resultados	50
6.1	Resultados da Validação Cruzada e Seleção dos Modelos	51
6.2	Ajuste de Eficiência em Função de $\langle\mu\rangle$	59
6.3	Testes de Hipóteses	63
6.4	Análise de Quadrante	65
6.5	Emulação das Cadeias de Filtragem	70
7	Conclusões e trabalhos futuros	73
7.1	Trabalhos futuros	74
	Referências Bibliográficas	75
A	Resultados dos Testes de Hipóteses	85
B	Produção Acadêmica	88
B.1	Resumos Publicados em Anais de Congresso	88

Lista de Figuras

2.1	Modelo Padrão de Partículas Elementares.	7
2.2	Interação das partículas com os detectores do experimento ATLAS.	9
3.1	Experimento ATLAS.	13
3.2	Sistema de coordenadas do experimento ATLAS.	14
3.3	Detector Interno do experimento ATLAS.	15
3.4	Sistema de calorimetria do experimento ATLAS.	16
3.5	Esboço das camadas do barril do LAr para $ \eta = 0$	19
3.6	Corte lateral do FCAL no tubo de suporte do criostato.	20
3.7	Ilustração da frente do módulo FCal1 durante a sua construção.	21
3.8	Arranjo entre as peças de tungstênio e os eletrodos de cobre na seção hadrônica do FCAL	21
3.9	O TDAQ do ATLAS em atuação durante a <i>Run 2</i>	23
4.1	Esquema do sistema de filtragem online de elétrons do ATLAS	24
4.2	Torres de filtragem utilizadas para a seleção de elétrons no <i>L1Calo</i> do ATLAS	26
4.3	Fluxograma empregado para seleção de elétrons no HLT do ATLAS	27
4.4	Simulação do desenvolvimento dos chuveiros hadrônico e eletromag- nético	30
4.5	Ilustração do processo de anelamento em uma dada região dos calo- rímetros do ATLAS	31
4.6	Esquema da aquisição de dados e Trigger do experimento CDF.	39
4.7	Ilustração do esquema de Trigger do experimento DØ	40
5.1	Modelo MLP com 5 neurônios.	44
5.2	Ilustração do modelo CNN.	45
5.3	Saída do modelo MLP em função de $\langle\mu\rangle$	47
6.1	Perfil médio dos anéis em dados de colisão antes e depois da redução de granularidade.	51
6.2	<i>Boxplot</i> do SP_{\max} para cada região do <i>ensemble</i>	53

6.3	Evolução do treinamento do modelo MLP2 em um <i>fold</i> para cada região de $20 \leq E_T < 30$ GeV.	57
6.4	Evolução do treinamento do modelo CNN em um <i>fold</i> para cada região de $20 \leq E_T < 30$ GeV.	58
6.5	Saída dos modelos em função de $\langle \mu \rangle$	59
6.6	Testes estatísticos de Wilcoxon e McNemar para região $15 \leq E_T < 20$ GeV.	64
6.7	Análise de quadrante para as variáveis E_{ratio} em dados de 2018.	67
6.8	Análise de quadrante para as variáveis R_η em dados de 2018.	68
6.9	Análise de quadrante para as variáveis R_{had} em dados de 2018.	69
6.10	Eficiência das cadeias em função de E_T	70
6.11	P_F das cadeias em função de η	71
A.1	Testes estatísticos de Wilcoxon e McNemar para região $20 \leq E_T < 30$	85
A.2	Testes estatísticos de Wilcoxon e McNemar para região $30 \leq E_T < 40$ GeV.	86
A.3	Testes estatísticos de Wilcoxon e McNemar para região $40 \leq E_T < 50$ GeV.	86
A.4	Testes estatísticos de Wilcoxon e McNemar para região $E_T \geq 50$ GeV.	87

Lista de Tabelas

3.1	Região de cobertura em η , granularidade e número de canais de leitura das camadas dos calorímetros	17
4.1	Fronteiras de η adotadas para o <i>ensemble</i> de cortes do ATLAS	29
4.2	Fronteiras para as regiões em η e E_T empregado pelo <i>ensemble</i> de redes neurais acima de 15 GeV.	31
4.3	Grandezas empregadas pelo ATLAS para discriminação de elétrons.	35
4.4	Grandezas empregadas pelo ATLAS para discriminação de elétrons na região <i>Forward</i>	37
5.1	Numero de anéis em cada camada.	43
5.2	Numero de anéis em cada camada após a redução de granularidade.	43
5.3	Parâmetros do algoritmo ADAM.	44
5.4	Cadeias de filtragem utilizadas no processo de emulação local.	49
6.1	Amostras de colisão obtidas dos dados de 2017 e 2018.	50
6.2	Valores P_D , P_F e SP para cada região do <i>ensemble</i> para e para todos os critérios de operação do Trigger antes do ajuste em função de $\langle\mu\rangle$	55
6.3	Valores P_D , P_F e SP para cada região do <i>ensemble</i> para e para todos os critérios de operação do Trigger após do ajuste em função de $\langle\mu\rangle$	61
6.4	Comparação dos resultados integrados considerando o ajuste em função de $\langle\mu\rangle$	62
6.5	Resultados para o teste de Wilcoxon para a comparação da saída do modelo $V8_F$ em relação aos modelos MLP com 2 neurônios e CNN.	63
6.6	Resultados para o teste de McNemar para a comparação modelo $V8_F$ em relação aos modelos MLP com 2 neurônios e CNN com o modelo $V8_F$ em cada um dos pontos de operação.	63
6.7	Resultados da emulação das <i>chains</i> em dados de colisão.	72

Lista de Símbolos

d_0	ver Tabela 4.3. 11, 35, 49
d_0/σ_{d_0}	ver Tabela 4.3. 35
$\Delta p/p$	ver Tabela 4.3. 35
$\Delta\eta_1$	ver Tabela 4.3. 35
$\Delta\phi_2$	ver Tabela 4.3. 35
$\Delta\phi_{res}$	ver Tabela 4.3. 35
E_{EM1}	energia medida na primeira camada do ECAL. 28
$E_{T,EM}$	energia transversa calculada no ECAL. 29
EM1	primeira camada EM. 28
EM2	segunda camada EM. 27, 28
EM3	terceira camada EM. 28, 41, 43, 50, 74
E/p	ver Tabela 4.3. 35
eProbabilityHT	ver Tabela 4.3. 35
E_{ratio}	ver Tabela 4.3. x, 28, 29, 35, 65, 67, 73
E_T	energia transversa.. x, xi, 4, 25, 27, 29–33, 35, 36, 38, 39, 43, 47, 49, 51, 55–59, 61, 63, 64, 70, 85–87
η	pseudorrapidez. x, xi, 4, 14, 29, 31, 36, 38, 41–43, 49–51, 55, 61, 67–69, 71, 73, 74
f_1	ver Tabela 4.3. 35
f_3	ver Tabela 4.3. 35
J/Ψ	méson J/Ψ , partícula instável que pode decair em elétrons. 41
LAr	argônio líquido. ix, 16, 19

$\langle\mu\rangle$	número médio de interações por cruzamento de pacote. viii–xi , 34 , 46 , 47 , 50 , 55 , 59–62 , 73
n_{blayer}	ver Tabela 4.3. 35
n_{pixel}	ver Tabela 4.3. 35
n_{Si}	ver Tabela 4.3. 35
n_{vtx}	número de vértices. 34
P_D	probabilidade de detecção de sinal. xi , 11 , 44 , 47 , 49 , 54–58 , 61 , 62 , 65 , 70 , 74
P_F	probabilidade de falso alarme. x , xi , 11 , 44 , 49 , 54–58 , 60–62 , 70 , 71 , 73 , 74
ϕ	ângulo azimutal. 14 , 38
p_T	momento transverso. 32
R_η	ver Tabela 4.3. x , 28 , 29 , 35 , 65 , 68
R_{had}	ver Tabela 4.3. x , 28 , 29 , 35 , 66 , 69
R_{had1}	ver Tabela 4.3. 35
R_ϕ	ver Tabela 4.3. 35
SP	índice soma-produto. xi , xiii , 44 , 45 , 47 , 55–58 , 61 , 73
SP_{max}	SP máximo. ix , 44 , 51 , 53
θ	ângulo polar. 14
TRT_PID	ver Tabela 4.3. 35
W	bóson Intermediário W. 7 , 39
$w_{\eta2}$	ver Tabela 4.3. 35
w_{stot}	ver Tabela 4.3. 35
Z	bóson Intermediário Z. 7 , 32 , 41 , 42 , 67–69 , 72

Lista de Abreviaturas

No caso de algumas abreviaturas internacionalmente conhecidas, optou-se por mantê-las em sua língua original.

ADAM	<i>Adaptive Moment Estimation.</i> xi, 43, 44
ALICE	<i>A Large Ion Collider Experiment.</i> 10
<i>Athena</i>	Principal infraestrutura em software do ATLAS que possibilita a execução do códigos para os diversos fins.. 22
ATLAS	<i>A Toroidal LHC Apparatus.</i> vii–ix, xi, 2–5, 8–11, 13–16, 18, 19, 21, 22, 24, 26–31, 33, 35–38, 42, 43, 46, 49, 54, 62, 67–69
BDT	<i>Boosted Decision Tree.</i> 11
BNL	<i>Brookhaven National Laboratory.</i> 6
CERN	<i>Centre Européene pour la Rechère Nucleaire.</i> 2, 6, 10
CMS	<i>Compact Muon Solenoid.</i> 2, 10, 38
CNN	Rede Neural Convolutiva. ix–xi, 4, 11, 43, 45, 47, 54–56, 58–60, 63–70, 73, 74, 85–87
COPPE/UFRJ	Instituto Alberto Luiz Coimbra de Pós-graduação e Pesquisa de Engenharia. 4
DØ	Experimento DØ. ix, 38–40
ECAL	Calorímetro Eletromagnético. xii, 8, 18, 25, 28, 33
EM	Eletromagnético. xii, 35
FastCalo	estágio <i>online</i> de pré-seleção rápida baseada em informação de calorimetria. 49, 70, 72, 73
FCAL	Calorímetro Dianteiro. vii, ix, 9, 16, 19–21

FEX	Algoritmo de Extração de Característica. 27, 28
FTK	<i>Fast TracKer</i> . 32
HAD	Hadrônico. 8
HCAL	Calorímetro Hadrônico. 8, 18, 19, 28
HEC	Tampa do Calorímetro Hadrônico. 16, 18, 19
HLT	Alto Nível de <i>Trigger</i> . viii, ix, 2–4, 22, 26, 27, 33, 34, 38, 49, 70, 72, 74
HYPO	Algoritmo de Hipótese. 28, 33
ID	Detector Interno. 14
EM _{isol}	Isolamento Eletromagnético. 25
HAD _{isol}	Isolamento Hadrônico. 25
KDE	Estimação de Densidade por <i>Kernel</i> . 33
L1	Primeiro Nível de Filtragem. 2, 22
L1Calo	Primeiro Nível de Filtragem para o Sistema de Calorimetria. viii, ix, 25, 26, 42, 49, 74
LHC	<i>Large Hadron Collider</i> . 2, 3, 6, 9, 10, 31, 42
LHCb	<i>Large Hadron Collider beauty experiment</i> . 10
MLP	<i>Perceptron</i> de Múltiplas Camadas. ix–xi, 4, 11, 30, 31, 43–45, 47, 51, 52, 54–57, 59–70, 73, 74, 85–87
MP	Modelo Padrão de Partículas Elementares. 3, 4, 6
MSE	Erro Quadrático Médio. 44, 56–58
<i>pdf</i>	Função de densidade de probabilidade. 33
PS	Pré-Amostrador. 16, 41, 43, 50, 74
ROC	<i>Receiver Operation Curve</i> . 56–58
RoI	Região de Interesse. 22, 25–27, 30–33, 42
CDF	The Collider Detector at Fermilab. ix, 6, 38, 39
RPROP	<i>Resilient Back-propagation</i> . 32

SCT	Detector de Rastreamento por Semicondutores. vii , 14 , 15 , 35
SUSY	Teoria de Supersimetria. 24
T&P	<i>Tag and Probe</i> . 32 , 41 , 42 , 67–69
TDAQ	Trigger e Sistema de Aquisição de Dados. 21 , 22
<i>TileCal</i>	Calorímetro Hadrônico de Telhas. 16 , 18 , 19
Trigger	Sistema de filtragem <i>online</i> . ix , xi , 2–5 , 22 , 25 , 26 , 28 , 38–41 , 48 , 55 , 61 , 70 , 72 , 74
TRT	Detector de Rastreamento por Transição de Radiação. vii , 14 , 15 , 35
TT	Torre de Filtragem. 25

Capítulo 1

Introdução

O avanço da tecnologia durante a Era da Informação propiciou o crescimento exponencial da quantidade de dados gerados e armazenados, oriundos das mais diversas aplicações e áreas de conhecimento. Este fenômeno, conhecido como Big Data, é caracterizado pela grande diversidade, volume e velocidade de produção da informação, características que tornam o processamento e gerenciamento destes dados por *software* inconcebível. Neste contexto, a procura por eventos raros torna-se desafiadora e extremante limitante. Por consequência, a criação de sistemas de filtragem e a otimização dos processos de armazenamento da informação para assegurar a confiabilidade e acessibilidade dos dados são impreteríveis.

Por ventura, para algumas aplicações onde o aumento do número de eventos é imprescindível mediante a raridade do sinal de interesse, a eficiência da filtragem deve ser alta e a tomada de decisão deve ser online assegurando a viabilidade do armazenamento físico da informação. Neste tipo de sistema, a latência é muitas vezes o fator impeditivo para a escolha de técnicas sofisticadas. Assim, um possível arranjo deste sistema seria o sequenciamento de níveis mais restritivos, em que os primeiros segmentos (ou níveis) utilizam sensores de leitura e métodos de classificação rápida (*online*), enquanto nos últimos níveis emprega-se plenamente a capacidade de processamento e os eventos são selecionados e armazenados para análise posterior (*offline*). Em virtude disto, a versão online pode ser desenvolvida a partir de uma adaptação da técnica aplicada ao processamento offline para as condições de latência e velocidade da seleção online.

Algumas técnicas utilizadas em problemas de identificação e classificação de eventos raros utilizam o conhecimento de áreas como: Ciência de Dados; Aprendizado de Máquinas e Inteligência Computacional. O êxito do emprego de modelos envolvendo, simultaneamente ou não, estas áreas de conhecimento é perceptível pela abundância de estudos e aplicações nas mais diversas áreas do conhecimento, como exemplo: a busca por eventos de interesse na triagem de pacientes com suspeita de patologias; procura por falhas ou predição de anomalias em equipamentos, dutos ou

construções civis; detecção de objetos por sistema de sonar passivo; identificação de partículas em experimentos de Física de Altas Energias.

1.1 Motivação

Na área de Física de Altas Energias, aceleradores e detectores gigantesco são utilizados para estudar partículas subatômicas e raios cósmicos. Aceleradores como o [LHC](#), (*Large Hadron Collider*) [1] situado no [CERN](#) (*Centre Européene pour la Recherche Nucleaire*) localizado em Genebra, Suíça, atualmente o maior colisionador de partículas do mundo, geram milhares de colisões por segundo em busca de eventos raros que permitirão a compreensão sobre as partículas elementares que constituem o universo e como são regidas as suas interações.

Em 2012, no [LHC](#), foi observado uma nova partícula bosônica com massa em torno de $125 \text{ GeV}/c^2$ com características compatíveis com o modelo teórico proposto, muitos anos antes por Peter Higgs e Robert Brout para o Bóson de Higgs [2–4]. Esta observação foi confirmada pelos experimentos [ATLAS](#) (*A Toroidal LHC Apparatus*) [5] e [CMS](#) (*Compact Muon Sollenoid*) [6] concomitantemente através de medidas independentes. Tal resultado proporcionou a estes cientistas o prêmio Nobel de física em 2013.

Para que os detectores sejam capazes de coletar dados provenientes de eventos extremamente raros como o Bóson de Higgs, com número de amostras suficiente para caracterizar esta assinatura mediante milhares de eventos oriundos de outros decaimentos e interações, que podem ter assinaturas semelhantes e que constituem uma enorme massa de ruído, o [LHC](#) concentra feixes de prótons que são acelerados a altas energias e geram colisões da ordem de 13 TeV de energia de centro de massa, a cada 25 ns. No experimento [ATLAS](#), o armazenamento total dos eventos na alta taxa (40 MHz) demandaria uma banda de 60 TB/s, o que é inconcebível, além de que seriam necessários anos para completar a coleta dos dados que seria majoritariamente composta por eventos de física ordinária. Desta forma, é indubitável a necessidade de um sistema de filtragem online que remova eventos de ruído e selecione os dados de interesse (normalmente eventos com pouca probabilidade de ocorrência) com objetivo de atingir uma taxa factível para o armazenamento e posterior análise offline.

O [ATLAS](#) [7, 8] possui um sistema de filtragem *online*, chamado [Trigger](#) [9], com objetivo de alcançar o tempo médio de decisão (latência) necessária para operar com a taxa de eventos produzida pelo [LHC](#). O [Trigger](#) do [ATLAS](#) é dividido em dois níveis de processamento sequenciais. O Primeiro Nível de Filtragem ([L1](#)) opera em hardware e reduz o fluxo de eventos para 100 kHz e opera com latência inferior a $2,5 \mu\text{s}$. O Segundo Nível de Filtragem, denominado [Alto Nível de Trigger](#) ([HLT](#)),

é baseado em *software* e é dividido em duas etapas: rápida e precisa. Este nível obteve uma taxa média de saída igual a 1 kHz durante o período de 2015 a 2018 [10].

No [ATLAS](#), o processamento *offline* é utilizado como referência para a tomada de dados, desta forma o [HLT](#) é implementado a partir de uma adaptação do modelo *offline*. Esta técnica garante a conformidade entre a tomada de decisão pelo sistema *online* e a referência. Todavia, é necessário utilizar técnicas para avaliar o impacto da tomada de decisão *online* nas amostras, isto pode ser avaliado a partir de análises físicas realizadas durante o processamento *offline*.

O [Trigger](#) do [ATLAS](#) opera a partir de técnicas de reconhecimento de padrões para a identificação de sinais de interesse, dentre eles partículas como os elétrons que foram fundamentais para a observação do Bóson de Higgs, além de serem importantes pois constituem o produto de uma série de outros decaimentos e processos raros que devem ser estudados pelos físicos para ajudar a compreender modelos teóricos como por exemplo o [Modelo Padrão de Partículas Elementares \(MP\)](#) e teorias além do Modelo Padrão, como a teoria da Supersimetria [11–15].

As assinaturas dos elétrons no [ATLAS](#) são oriundas do detector de traços e do sistema de calorimetria [16, 17]. Os calorímetros são compostos por mais de 200 mil canais com baixa latência de leitura e são responsáveis por absorver e mensurar a energia das partículas [18]. A interação das partículas com o material ativo do calorímetro produz uma cascata de partículas cujo formato é fundamental pois auxilia na identificação da partícula incidente e é basilar para o sistema de filtragem online.

O detector de traços mede a trajetória e o momento das partículas [19, 20]. Os sinais medidos por estes detectores estão submetidos a distorções devido a localização da interação ou incidência no detector, a energia da partícula e o empilhamento de sinais ocasionado pela alta luminosidade do [LHC](#).

O aumento da luminosidade¹ e a conseqüente elevação da taxa de colisões no [LHC](#), com objetivo de aumentar a estatística de eventos raros, tem amplificado o empilhamento dos sinais devido a elevação da ocupação do detector. Este fato assegura a necessidade da utilização de algoritmos rápidos e com alta capacidade discriminante no início da cadeia de filtragem de elétrons. Como os calorímetros possuem flutuações na uniformidade dos canais de leitura e as assinaturas oriundas dos processos físicos são dependentes da energia, uma solução viável para manter a alta detecção com uma baixa taxa de falsos positivos é o desenvolvimento de modelos específicos para determinadas regiões de energia e posição. Mediante isto, a construção de um ensemble de modelos dedicados a posição no calorímetro e a

¹Na Física de Partículas Elementares a luminosidade (\mathcal{L}) é definida pela multiplicação do inverso da seção de choque (σ) de produção dos eventos pelo número de eventos (N) em função do tempo (t). Matematicamente: $\mathcal{L} = \frac{1}{\sigma} \frac{dN}{dt}$

energia transversa da partícula é um artifício para contornar as não-linearidades do detector durante a seleção online.

Nesse cenário, o [ATLAS](#) adotou uma nova estratégia para a etapa rápida do sistema de filtragem online de elétrons baseada em informação de calorimetria e que atua através da compactação da informação e conhecimento especialista, este algoritmo é chamado de *NeuralRinger* [21–23]

O *NeuralRinger* foi proposto no início da década de 1990, numa colaboração desenvolvida no Instituto Alberto Luiz Coimbra de Pós-graduação e Pesquisa de Engenharia (COPPE/UFRJ) [24]. O método, adotado pelo [ATLAS](#) a partir de 2017², compacta a informação de calorimetria e a utiliza como entrada em um ensemble de modelos neurais especialistas do tipo [MLP](#) (*Multi-Layer Perceptron*). Este modelo foi adotado pelo [ATLAS](#) para a etapa rápida do [HLT](#) para energia transversa (E_T) acima de 15 GeV e para região central do detector que abrange $|\eta| < 2,5$. Para regiões com $|\eta| > 2,5$, ainda não existe [Trigger](#), nem nenhum sistema de seleção para elétrons online. Desta maneira, a identificação de elétrons nesta região do calorímetro é realizada apenas através do processamento *offline*. A extensão do *NeuralRinger* para a região mais externa do detector é instigante, uma vez que a identificação ótima de elétrons para regiões de alta pseudorapidez do detector propiciam a expansão do espaço de fase para a realização de medidas e pesquisa sobre processos como: *Drell-Yan*; QCD (difrativo e espalhamento elástico, dinâmica de *low-x partons*, Monte Carlo para raios cósmicos); processos eletrofracos em $\gamma\gamma$; interação e física de Higgs (*vector-boson-fusion* e produção exclusivamente central), tais medidas auxiliam na comprovação de teorias como o [MP](#) [25].

1.2 Objetivos

O objetivo deste trabalho é construir a filtragem online de alto nível na sua etapa inicial de processamento com base na calorimetria para a região *forward* ($|\eta| > 2,5$) mediante a emulação das condições desta região a partir de dados da parte mais externa do barril do sistema de calorímetros do [ATLAS](#) ($2,37 \leq |\eta| < 2,47$). O objetivo desta emulação é realizar uma redução sintética de granularidade, uma vez que não existe reconstrução *online* na região *Forward*. Além disto, este trabalho também avaliou o desempenho de modelos [MLP](#) e [CNN](#) ³ para tomada de decisão

²A proposta original do algoritmo *NeuralRinger* não era baseada em um ensemble de modelos, mas sim em um modelo único para todo o espaço de fase. O método utilizando um ensemble de modelos especialista para cada região de E_T e η foi criado em 2016 e começou a operar no [ATLAS](#) em 2017.

³Atualmente o *NeuralRinger* opera com um ensemble de modelos [MLP](#) na região central do calorímetro, isto propiciou o estudo da performance deste modelo para as condições da região *Forward*. A implementação do modelo profundo foi motivada pelo desenvolvimento deste tipo de rede neural para a região central do calorímetro [26] e para identificação de partículas *offline* [27],

online na partição mais externa do barril de modo a emular o comportamento destes modelos para futuras aplicações no desenvolvimento de um [Trigger](#) para o setor de alta pseudorapidez do experimento [ATLAS](#).

1.3 Organização da dissertação

Este documento foi dividido por capítulos da seguinte forma: O Capítulo [2](#) introduz os conhecimentos sobre física de altas energias, aceleradores e detectores de partículas que são necessários para a compreensão deste trabalho. O Capítulo [3](#) apresenta o experimento [ATLAS](#) e detalha seus subsistemas e detectores que são utilizados para coleta dos dados empregados nesta dissertação. O Capítulo [4](#) apresenta o sistema de filtragem online de elétrons do [ATLAS](#) e as estratégias empregadas na identificação de elétrons na região *Forward*. O Capítulo [5](#) descreve o método proposto nesta dissertação. O Capítulo [6](#) apresenta os resultados encontrados e, por fim, o Capítulo [7](#) expressa as conclusões e as perspectivas futuras de pesquisa.

ambos com resultados estimulantes.

Capítulo 2

A física experimental e de altas energias e o LHC

O estudo da física de partículas foi fundamento a partir do trabalho publicado em 1935 por Yukawa [28]. A partir desta publicação as experiências com raios cósmicos ¹ foram impulsionadas e surgiram colaborações internacionais para estudo dos mesmos, especialmente com técnicas de emulsões expostas a grandes altitudes. Posteriormente, com a descoberta do pión por Lattes, Occhialini e Powell [29] teve início, na década de 1950, a construção de grandes aceleradores de partículas como o Cosmotron em *Brookhaven National Laboratory (BNL)*, SLAC em Stanford e o *Fermi National Accelerator Laboratory (Fermilab)* nos Estados Unidos, Desy na Alemanha, Dubna e Serpukhov na União Soviética e o **CERN** na Suíça [11, 15].

O **CERN** foi criado em 1953 para estudo de física nuclear e de altas energias. O Synchro-Cyclotron (SC) foi o primeiro acelerador do **CERN** e sua construção foi iniciada em 1954 mas o programa experimental teve início em 1958. Anos depois com o desenvolvimento do complexo de aceleradores do **CERN**, o SC torna-se uma das primeiras etapas de aceleradores, fornecendo e injetando partículas diretamente em aceleradores maiores. O **LHC**, atualmente o maior acelerador de partículas do mundo, estreitou o seu programa a partir de 2008, sendo uma das últimas adições ao complexo de aceleradores do **CERN**.

2.1 As partículas elementares e o Modelo Padrão

O **MP** descreve as partículas elementares, suas interações e três das quatro forças fundamentais da natureza: a forte, a fraca e a eletromagnética. Este modelo categoriza as partículas em dois grupos principais: os férmions e os bósons [12, 13, 30].

¹Os raios cósmicos são compostos por partículas altamente energéticas provenientes do cosmos que atingem a atmosfera terrestre e interagem com os núcleos dos gases que a compõem gerando chuvas de partículas.

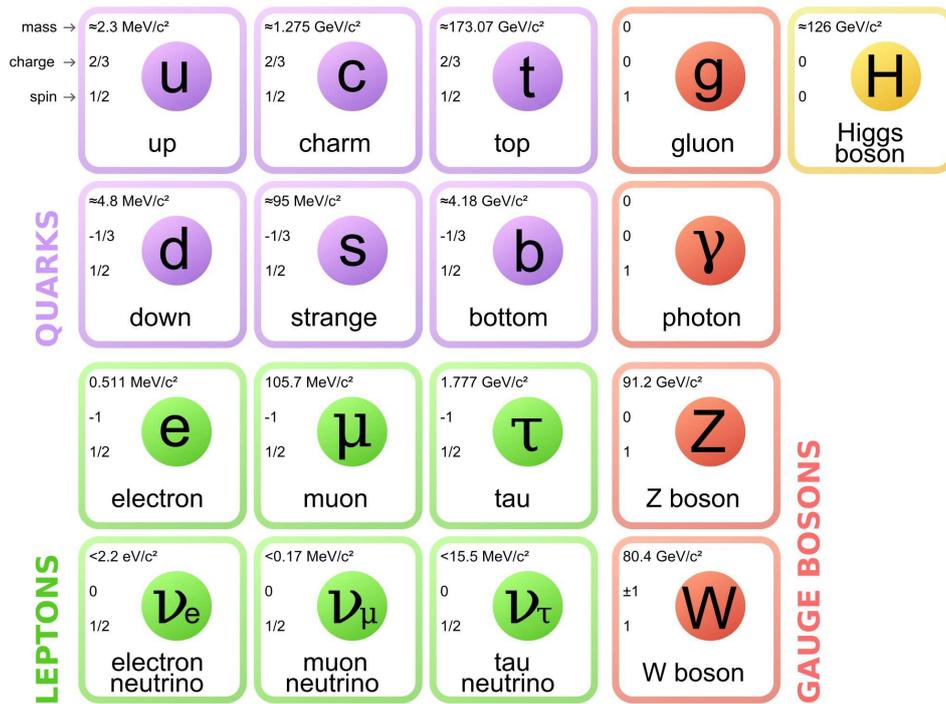


Figura 2.1: Modelo Padrão de Partículas Elementares. Extraído de [28]

Os férmions são partículas que obedecem à estatística de Fermi-Dirac ². Este grupo é composto por quarks e léptons. Os léptons, por sua vez, são partículas de spin semi-inteiro ($\hbar/2$, $3\hbar/2$, $5\hbar/2$, etc), supostamente sem estrutura interna e que podem ser detectados isoladamente. Existem seis tipos diferentes de léptons e seis anti-léptons, estando eles distribuídos em três gerações ou famílias. Os quarks formam os hádrons que podem ser subdivididos em bárions e mésons. Os bárions são formados por três quarks e os mésons são formados por um par quark-antiquark, não sendo necessariamente o antiquark a antipartícula do quark que forma o par. Os quarks não são detectados em estado isolado, sendo medidos apenas em estados ligados, como os citados. Existem seis “sabores” de quarks e seis “sabores” de antiquarks e estes são classificados em três famílias (gerações), como ilustra a Figura 2.1.

Os bósons são partículas de spin inteiro que obedecem a estatística de Bose-Einstein. As interações fundamentais são mediadas por bósons. O fóton é o mediador da interação eletromagnética, o gráviton (supostamente) é o mediador da interação gravitacional (ainda não foi detectado experimentalmente), o W e o Z os mediadores da força fraca e o glúon é o mediador da força forte. Este possui carga de cor assim como os quarks e não deve ser observado em estado de partícula isolada.

²A estatística que uma partícula obedece está associada com a simetria da função de onda que descreve um par de partículas iguais, se porventura existe a troca entre tais partículas. A função de onda que descreve dois bósons idênticos deve ser simétrica com relação à troca de tais partículas e a que descreve dois férmions deve ser antissimétrica [12, 15]

2.1.1 Interação das partículas com a matéria

A detecção de uma partícula é feita mediante a interação desta com um meio material. As interações dependem da natureza da partícula incidente e de suas características físicas, como por exemplo massa, energia, momento, carga, etc e das propriedades do meio tais como número atômico, massa e até mesmo a estrutura molecular. A compreensão dos processos de interação com matéria e das probabilidades de decaimento das partículas são fundamentais para a construção de aparatos capazes de detectar e identificar novas partículas com precisão e confirmar teorias físicas sobre a origem e a composição da matéria.

Nos grandes experimentos de física de partículas, como no [ATLAS](#), o processo para detecção é realizado através da interação da partícula com o material que compõe o detector. Esta interação gera sinais que são tratados e manipulados para obter as propriedades da partícula incidente. Usualmente os experimentos possuem vários detectores com o objetivo de garantir precisão e devido sobretudo a complexidade da obtenção de informações para identificação das partículas por um único detector como por exemplo: medidas de momento e energia, carga, posição no detector, posição dos vértices de interação, dentre outras variáveis.

Para lidar com isto o [ATLAS](#) possui um conglomerado de subsistemas formado pelo detector interno, o sistema de calorimetria e o detector de múons (o capítulo 3 apresenta os subsistemas do [ATLAS](#) com detalhes).

A interação das partículas com a matéria do calorímetro gera uma cadeia de eventos decorrendo da multiplicação do número de partículas até sua extenuação, este processo é chamado de chuva de partículas. Existem duas possibilidades para o desenvolvimento do chuva. Se a partícula em questão for um elétron ou fóton, o desenvolvimento é dado por uma cadeia de produção agregando, em sua maioria, elétrons e fótons, ou seja, léptons. No outro caso, partículas hadrônicas (hádrons) podem decair tanto em outras partículas hadrônicas quanto em léptons.

No [ATLAS](#) os calorímetros dedicam-se a detecção dos processos de desenvolvimento do chuviros. O [ECAL](#) é destinado a detecção de chuviros oriundos, sobretudo, de interações eletromagnéticas; o [HCAL](#) é responsável pela medida da energia e o [HAD](#) pela contenção dos chuviros oriundos da interação forte, a Figura 2.2 ilustra a interação das partículas nos detectores do experimento [ATLAS](#). No caso dos neutrinos, o desafio para sua detecção resulta da mínima seção de choque de interação com os núcleos do material por via da interação fraca, único meio de interação possível para essa partícula. Por isso, a estratégia para detecção de neutrinos é sempre indireta. Nesse caso, assume-se que toda energia faltante é dada por neutrinos ao aplicar o conceito de conservação do momento transversal e, para isso, propriedade de hermeticidade do detector é necessária para as demais partículas, ou

seja, ampla cobertura em η do detector, e conseqüentemente dos calorímetros. No [ATLAS](#) isto é feito a partir do [FCAL](#).

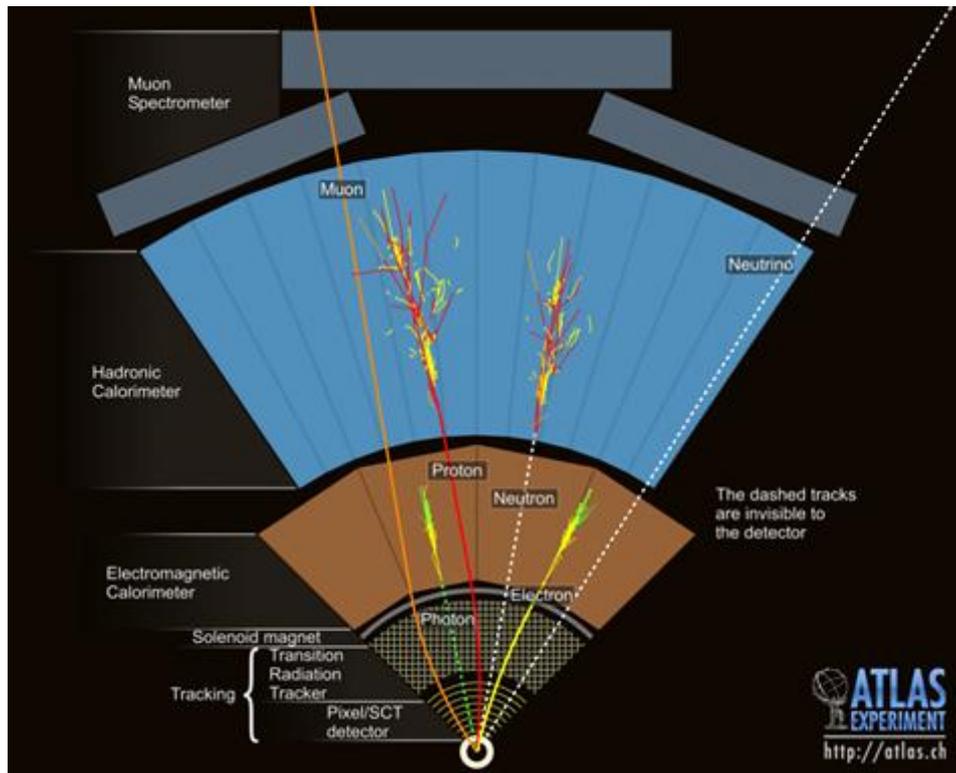


Figura 2.2: Interação das partículas com os detectores do experimento [ATLAS](#). Extraído de [31]

2.1.2 Física de interesse nas regiões de alta pseudorapidez do detector

O [LHC](#), na *Run 3*, irá colidir prótons com energia de centro de massa em torno de 14 TeV [32], inaugurando um espaço de fase sem precedentes para a produção de partículas que abrangem $\Delta\eta \approx 20$ unidades de pseudorapidez. Muitos processos de dispersão interessantes (a maioria mediados por interações sem cor ³ possuem partículas emitidas em ângulos muito pequenos em relação a linha do feixe. Esses processos são identificados por partículas *Forward* (jatos, prótons, léptons, íons) nos estados finais [25].

Dois dos principais mecanismos da produção de Higgs estão relacionados diretamente com a emissão de partículas com alta pseudorapidez são eles a produção da fusão de bósons vetoriais (VBF) e o canal exclusivamente central onde o Higgs é produzido a partir da fusão de glúons. [33]

Muitos aspectos da física da interação forte também podem ser estudados com os detectores *Forward*, tais como processos difrativos suaves (*soft diffractive processes*),

³cor é um número quântico associado aos quarks.

seção de choque elástica p-p, seção de choque de difração de regime duro, física de *low-x QCD*, saturação de glúons, evolução da cromodinâmica quântica (QCD) não linear, *multi-parton scattering*, processos de Drell-Yan [34], entre outros processos [33]. De forma similar os processos de eletrodinâmica quântica (QED) como $\gamma\gamma \rightarrow l^+l^-$ e o estudo de acoplamentos anômalos de bósons de gauge também possuem produção próxima da linha do feixe.

Ainda assim, o sistema de filtragem online de elétrons é projetado para operar somente na região central do detector ($\eta < 2,5$), não contemplando, portanto, a região *Forward*. Todavia muitos dos processos citados possuem elétrons de alta pseudorapidez em seus estados finais e a seleção online de elétrons para esta região auxiliaria no estudo destes processos uma vez que isto reduziria a perda de eventos com a física de interesse.

2.2 Large Hadron Collider (LHC)

No CERN são utilizados os maiores e mais complexos instrumentos científicos para criar as condições necessárias na detecção e estudo dos constituintes básicos da matéria e da antimatéria, com objetivo de possibilitar a confirmação de teorias fundamentais da física de partículas. Para gerar essas condições, o CERN opera um conjunto de aceleradores de partículas, entre os quais o maior acelerador de partículas do mundo, o LHC.

O LHC acelera 2 feixes de partículas a altas energias que colidem em quatro pontos dentro do acelerador onde estão instalados detectores de partículas para registrar os resultados destas colisões. O LHC possui 27 km de circunferência e 7 m de diâmetro e está situado a 100 m abaixo da superfície [1].

O LHC colide feixe de prótons com energia de centro de massa equivalente até 13 TeV, bem como feixes de íons pesados (Pb) com energia de 2,76 TeV por nucleon (cerca de 575 TeV por íon) [35]. Essas interações ocorrem em quatro pontos ao redor do LHC, onde estão localizados os principais experimentos. São eles: *A Large Ion Collider Experiment (ALICE)*, criado com objetivo de estudar a física de íons pesados, *Large Hadron Collider beauty experiment (LHCb)* especializado na física do quark b, *Compact Muon Solenoid (CMS)* e o *ATLAS*.

2.3 Inteligência computacional em física de altas energias

O interesse pela Aprendizagem de Máquina (*Machine Learning*) explodiu na última década. Com desenvolvimento tecnológico acelerado, é notória a interação cada

vez maior das aplicações de computador com seres humanos. Software de detecção de *spam*, sistemas de recomendação, marcação em fotos de redes sociais, assistentes pessoais ativados por voz, carros autônomos, *smartphones* com reconhecimento facial, entre outras. Fundamentalmente, a utilização de algoritmos para extrair informações de um montante crescente de dados provenientes destas aplicações se faz necessário. As Redes Neurais Artificiais têm sido amplamente utilizadas neste contexto e modelos como MLPs e CNNs são exemplos citados com frequência cada vez maior pela obtenção de resultados satisfatórios para problemas de classificação e estimação. Encontram-se aplicações contendo Aprendizado de Máquinas em Física de Altas Energias principalmente nos canais de busca física ou na discriminação de estados finais de uma série de partículas. As principais técnicas aplicadas são *Boosted Decision Tree* (BDT), *Perceptron de Múltiplas Camadas* (MLP) e Rede Bayesiana [36–39].

Especificamente para identificação de elétrons, as primeiras propostas com aplicação de redes neurais envolveram: a aplicação na análise física e proposta para atuação na filtragem online de elétrons no d_0 [40]; exercício considerando a separação elétron-fóton em dados do experimento E734 [41] dedicado a medição de espalhamento elástico do neutrino do elétron. Os resultados mostram superioridade de eficiência de seleção com MLP em relação às referências em todos os casos abordados.

O Experimento (H1) [42] desenvolveu redes neurais [43–45] para a filtragem online em objetos físicos de interesse do experimento. A implementação foi realizada em hardware para a atuação no segundo nível de filtragem com 20 μ s de latência. O sistema operou em paralelo desde o início do experimento com outra decisão baseada em cortes lineares, complementando-a e possibilitando coletar estatística para processos de difícil análise, onde é citado o caso de processos de produção de mésons.

No ATLAS, em especial na identificação de elétrons, a partir de 2017, uma estratégia para filtragem online de elétrons baseado um ensemble de redes neurais artificiais foi adotado mediante o emprego do algoritmo *NeuralRinger* para a região central do detector e energias transversas acima de 15 GeV. A adoção desta técnica permitiu a redução significativa da taxa de falsos positivos (P_F), enquanto a detecção (P_D) foi mantida em comparação ao método anterior que baseava-se em cortes lineares em variáveis físicas extremamente discriminantes (*Cut-Based*) [21, 22, 26].

O ATLAS também realizou estudos utilizando um modelo neural profundo (DNN) na identificação offline. O modelo proposto em [27] contém 10 camadas escondidas (cada uma com 256 neurônios) e uma camada de saída com apenas um neurônio. Os resultados para classificação que foram apresentados demonstraram grande superioridade em relação a estratégia de seleção *offline* atualmente utilizada [46] (máxima verossimilhança). Recentemente, uma versão simplificada, com menos

camadas, do DNN foi proposta para atuar no último estágio de seleção de elétrons no online. Todavia, essa proposta ainda encontra-se em desenvolvimento.

Capítulo 3

O Experimento ATLAS

A *Toroidal LHC Apparatus* (ATLAS),[47] ilustrado na Figura 3.1, é um experimento de propósito geral, ou seja, foi construído para estudar e medir a maior variedade possível de sinais, isto permite que novos processos ou partículas físicas possam ser detectados e suas propriedades medidas.

O ATLAS tem 44 m de comprimento, 25 m de altura e pesa em torno de 7000 T. Ele possui formato cilíndrico e é formado por um conjunto de sub-sistemas, cada um com características e finalidades próprias. Os principais são: o detector interno (*inner detector*), o sistema de calorimetria e o sistema de múons.

A colaboração internacional ATLAS envolve mais de 3000 pesquisadores de mais de 174 instituições e laboratórios de 38 países. Esses números incluem a COPPE/UFRJ, Instituto de Física da UFRJ e o Instituto de Física da UERJ.

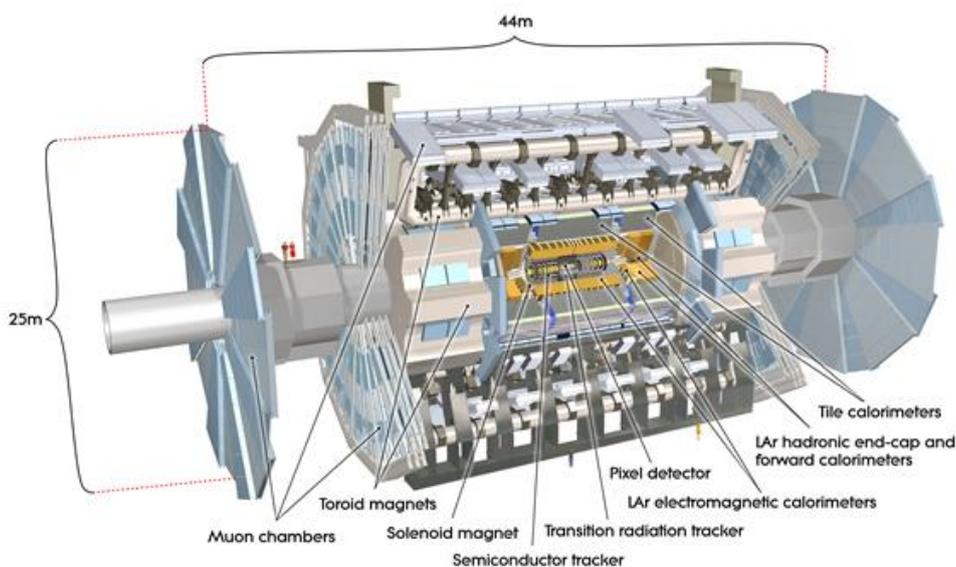


Figura 3.1: Experimento ATLAS. Extraído de [48]

3.1 Sistema de Coordenadas do ATLAS

O ATLAS utiliza um sistema de coordenadas cilíndricas baseada em duas variáveis: η e ϕ (Figura 3.2). O ângulo ϕ é definido como o ângulo radial, ou seja é formado pela projeção da trajetória da partícula no plano perpendicular ao eixo formado pelo feixe de partículas no ponto de colisão. A pseudorapidez η permite mapear qualquer ponto no espaço do detector e é dada pela Equação (3.1). O ângulo formado entre a direção do feixe e a trajetória da partícula é chamado θ .

$$\eta = -\log\left(\frac{\theta}{2}\right) \quad (3.1)$$

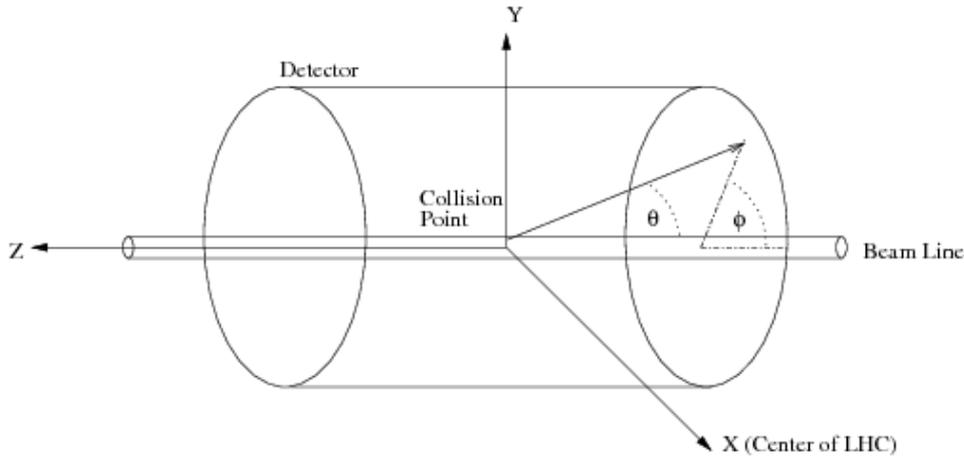


Figura 3.2: Sistema de coordenadas do experimento ATLAS. Extraído de [49]

3.2 Detector Interno

O Detector Interno (ID) [19, 20] (Figura 3.3) é composto por um conjunto de detectores de alta precisão posicionados em torno do eixo de colisão: o Detector de Pixel [50], o Detector de Rastreamento por Semicondutores (SCT) [51] e o Detector de Rastreamento por Transição de Radiação (TRT) [52]. O ID foi desenvolvido com o propósito de rastrear a trajetória das partículas eletricamente carregadas, medir a sua carga, o momento e os vértices primário e secundário que correspondem respectivamente ao ponto de interação p-p e o ponto de decaimento de uma partícula gerada após a interação primária. Este detector possui cobertura simétrica em ϕ para $|\eta| < 2,5$, esta limitação está relacionada à região com nível de incidência de radiação tolerável pelo equipamento.

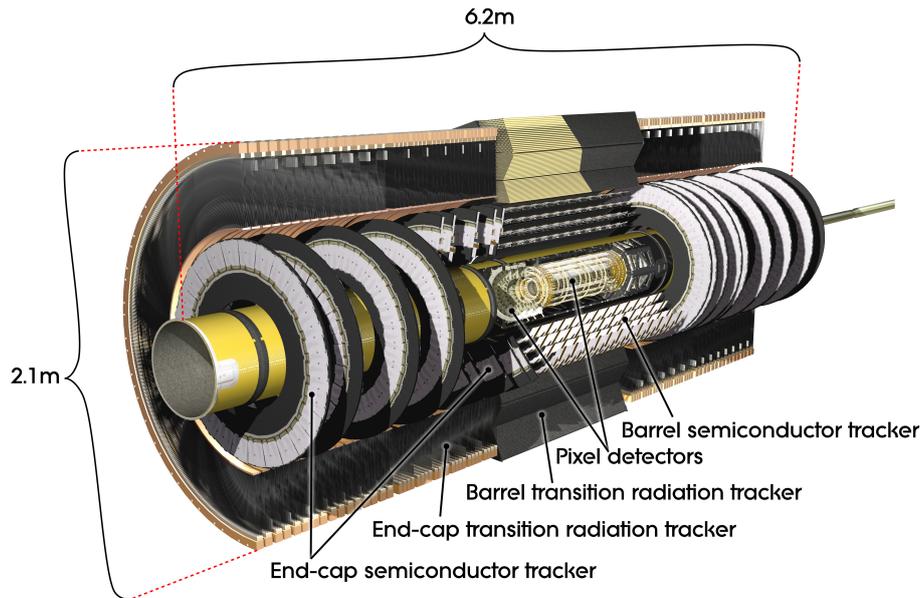


Figura 3.3: Detector Interno do experimento [ATLAS](#). Extraído de [53]

3.2.1 O Detector de Pixel

O Detector de Pixel é constituído por uma estrutura de pixels de silício e foi projetado para fornecer três pontos de alta precisão. O sistema possui três barris a uma distância radial média de aproximadamente 5 cm, 10 cm e 13 cm, as três tampas, por sua vez, estão posicionadas em cada um dos lados com distância radial de 11 e 20 cm. A camada mais interna deste detector está localizada o mais próximo possível do ponto de interação com objetivo de fornecer a resolução ideal do parâmetro de impacto. O Detector de pixel fornece a informação de rastreamento crítica para o reconhecimento de padrão próximo ao ponto de colisão e é responsável, em grande parte, pela identificação de vértices secundários.

3.2.2 SCT

O [SCT](#) é composto por quatro camadas duplas de microfibras de silicone. Cada componente possui em torno de 768 canais de leitura com $80 \mu\text{m}$ de afastamento. As tampas possuem construção semelhante mas utilizam tiras cilíndricas para formar um conjunto radialmente alinhado e com cerca de 6,3 M de canais que permitem distinguir traços separados a uma distância de $200 \mu\text{m}$.

3.2.3 TRT

O [TRT](#) possui fibras preenchidas com um material que emite radiação de transição quando uma partícula o atravessa. A reação gerada pela partícula carregada ao passar pela fibra preenchida permite a leitura dos dados do traço nesta região.

O barril contém cerca de 50 mil canais, divididos ao meio para reduzir a ocupação e sua leitura em cada ponta. A tampa contém 300 sensores radiais, com a leitura na ponta externa. As medições realizadas pelos canais são em formas de impulsos e dão uma resolução espacial de $170 \mu\text{m}$ por canudo.

3.3 Sistema de Calorimetria

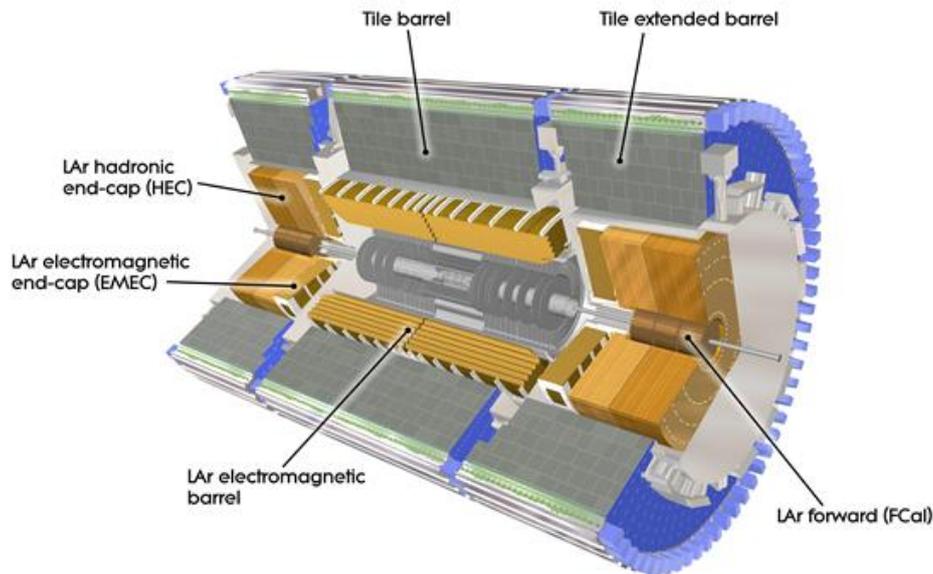


Figura 3.4: Sistema de calorimetria do experimento *ATLAS*. Extraído de [53]

O sistema de calorimetria do *ATLAS* [7, 8, 16] é constituído por calorímetros de amostragem com simetria em relação ao ângulo azimutal ϕ e formados por células com geometria aproximadamente retangular no plano $\eta \times \phi$. Os calorímetros do *ATLAS* são subdivididos em duas partes principais, a parte eletromagnética é composta pelo calorímetro de Argônio Líquido (*LAr*) [17] e a parte hadrônica pelo *Calorímetro Hadrônico de Telhas* (*TileCal*) e pelas tampas (*HEC*). Para fornecer hermeticidade e cobrir a região mais próxima do feixe o *ATLAS* utiliza um calorímetro com granularidade menor, o *FCAL*. Na região com pseudorapidez $|\eta| < 1,8$, situado antes dos calorímetros, está o *Pré-Amostrador* (*PS*) que é formado por uma camada fina de *LAr* e com ausência de meio passivo, por este motivo não caracteriza um calorímetro. A função do *PS* é absorver as partículas que provém de chuviscos formados antes dos calorímetros.

A Tabela 3.1 apresenta o número de canais de leitura, a segmentação e a granularidade utilizada em cada seção do sistema de calorimetria. A granularidade é reduzida para as camadas mais externas já que estas possuem células maiores e isto afeta a precisão da medida de energia.

Pré-amostrador (PS)	Barril	Tampa	
Cobertura	$ \eta < 1,52$	$1,5 < \eta < 1,8$	
Segmentação Longitudinal	1 camada	1 camada	
Granularidade ($\Delta\eta \times \Delta\phi$)	$0,025 \times 0,1$	$0,025 \times 0,1$	
Canais de Leitura	7808	1536 (ambos os lados)	
Eletromagnético	Barril	Tampa (EMEC)	
Cobertura	$ \eta < 1,475$	$1,375 < \eta < 3,2$	
Segmentação Longitudinal	3 camadas	3 camadas	$1,5 < \eta < 2,5$
		2 camadas	$1,375 < \eta < 1,5$
		2 camadas	$2,5 < \eta < 3,2$
Granularidade ($\Delta\eta \times \Delta\phi$)			
Camada 1	$0,003 \times 0,1$	$0,025 \times 0,1$	$1,375 < \eta < 1,5$
		$0,003 \times 0,1$	$1,5 < \eta < 1,8$
		$0,004 \times 0,1$	$1,8 < \eta < 2,0$
		$0,006 \times 0,1$	$2,0 < \eta < 2,5$
		$0,1 \times 0,1$	$2,5 < \eta < 3,2$
Camada 2	$0,025 \times 0,025$	$0,025 \times 0,025$	$1,375 < \eta < 2,5$
		$0,1 \times 0,1$	$2,5 < \eta < 3,2$
Camada 3	$0,050 \times 0,025$	$0,050 \times 0,025$	$1,5 < \eta < 2,5$
Canais de Leitura	101760	62208 (ambos os lados)	
Had. Telhas Cintilantes (Tile-Cal)	Barril	Barril estendido	
Cobertura	$ \eta < 1,0$	$0,8 < \eta < 1,7$	
Segmentação Longitudinal	3 camadas	3 camadas	
Granularidade ($\Delta\eta \times \Delta\phi$)			
Camadas 1, e 2	$0,1 \times 0,1$	$0,1 \times 0,1$	
Camada 3	$0,2 \times 0,1$	$0,2 \times 0,1$	
Canais de Leitura	5760	4092 (ambos os lados)	
Had. Argônio Líquido (HEC)	Tampa		
Cobertura		$1,5 < \eta < 3,2$	
Segmentação Longitudinal		4 camadas	
Granularidade ($\Delta\eta \times \Delta\phi$)		$0,1 \times 0,1$	$1,5 < \eta < 2,5$
		$0,2 \times 0,2$	$2,5 < \eta < 3,2$
Canais de Leitura		5632 (ambos os lados)	
Calorímetro Dianteiro (FCal)	Dianteiro		
Cobertura		$3,1 < \eta < 4,9$	
Segmentação Longitudinal		3 camadas	
Granularidade ($\Delta\eta \times \Delta\phi$)		$\sim 0,2 \times 0,2$	
Canais de Leitura		1762 (ambos os lados)	

Tabela 3.1: Região de cobertura em η , granularidade e número de canais de leitura das camadas dos calorímetros. Adaptado de [54].

3.3.1 Calorímetro Eletromagnético

O Calorímetro Eletromagnético do [ATLAS](#) divide-se em duas partes: a região central (também chamada de barril) que abrange $|\eta| < 1,475$ e as tampas que cobrem $1,375 < |\eta| < 3,2$. O [ECAL](#) utiliza argônio líquido como material ativo, eletrodos de cobre como material absorvedor e placas de chumbo como meio passivo. A estrutura deste calorímetro lembra o formato de um acordeão, este formato garante uma cobertura natural e sem fissuras para ϕ e possibilita a leitura rápida dos sinais originados a partir de eletrodos localizados na parte frontal e traseira. Entretanto, devido a complexidade da estrutura, a granularidade na região das tampas é menor em relação à ϕ , uma vez que a proporção das ondas do acordeão cresce proporcionalmente ao raio. Esta estrutura possibilita a segmentação do calorímetro a partir de camadas com diferentes granularidades. Ao todo o [ECAL](#) possui três camadas.

- A primeira camada do [ECAL](#) (E_1)

A primeira camada do [ECAL](#) também é chamada de camada de tiras, em inglês *strips*, tendo em vista que é composta por tiras finas com alta granularidade em η . A alta precisão permite uma boa leitura da posição das partículas, o que é fundamental para a identificação de fótons, visto que estes não são medidos no detector interno.

- A segunda camada do [ECAL](#) (E_2)

A segunda camada, ou camada central, é seccionada transversalmente em torres quadradas de $(\Delta\eta \times \Delta\phi) \approx (0,025 \times 0,025)$. Esta camada permite a ótima contenção do perfil do chuveiro eletromagnético para a medição de energia e é responsável pela maior parte de sua absorção.

- A terceira camada do [ECAL](#) (E_3)

A camada E_3 , ou camada traseira, é a última camada do [ECAL](#) e contribui para a classificação elétron-jato para chuveiros com energias mais altas. A granularidade nesta região é idêntica a da camada central para ϕ mas é duas vezes menos precisa em relação a η . Na a região das tampas ($2,5 < |\eta| < 3,2$) existem apenas duas camadas com granularidade de $(\Delta\eta \times \Delta\phi) = (0,1 \times 0,1)$.

3.3.2 Calorímetro Hadrônico

Ao redor do [ECAL](#), encontra-se o calorímetro hadrônico ([HCAL](#)). O calorímetro hadrônico do [ATLAS](#) é subdividido em duas partes: o barril, chamado de [TileCal](#) e as tampas ([HEC](#)).

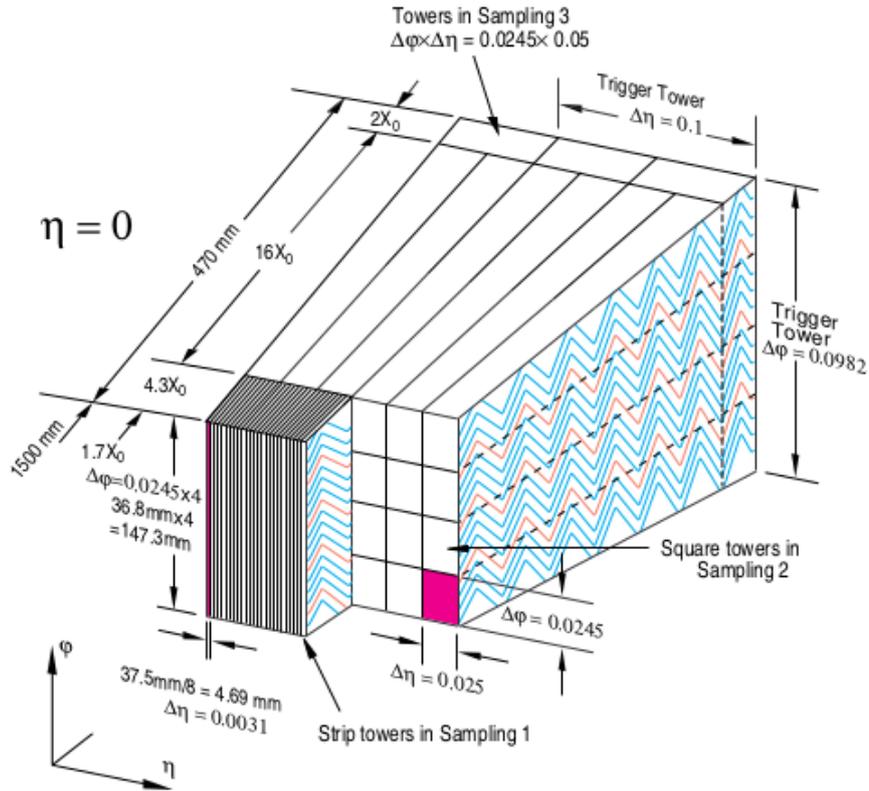


Figura 3.5: Esboço das camadas do barril do LAr para $|\eta| = 0$. Extraído de [16]

O *TileCal* é composto por telhas de cintiladores de plástico que atuam como material ativo e aço como material passivo. A região central do detector é segmentada longitudinalmente com objetivo de melhorar a resolução de energia e melhorar a identificação das partículas através da calibração realizada pela ponderação do depósito em cada uma das camadas. O *TileCal* possui três camadas, a camada H0, a H1 e a H2.

As tampas do calorímetro hadrônico utilizam LAr como meio ativo e cobre como elemento passivo. Cada HEC é composto por duas tampas e cada uma delas possui 32 módulos idênticos. A primeira tampa é formada por 24 chapas de cobre e a segunda por 16 e estão separadas por uma fissura de 8,5 mm onde localiza-se o argônio líquido e três eletrodos. As tampas possuem 4 camadas, sendo as duas centrais agrupadas em uma única camada para manter a uniformidade e a segmentação longitudinal do HCAL.

3.3.3 FCAL

O FCAL (Figura 3.6)[33, 55] está localizado próximo do feixe com objetivo de cobrir partículas com alto momento transversal oriundas das colisões próton-próton no ATLAS. A estrutura utilizada no FCAL foi desenvolvida especificamente para ambientes com alta taxa com objetivo de fornecer hermeticidade para medida de

energia transversa e também para identificação de jatos e partículas na região dianteira. O **FCAL** utiliza LAr como meio amostrador e é subdividido em três camadas. A primeira camada (F1CAL) utiliza uma matriz de cobre contendo buracos distribuídos igualmente como material absorvedor. Estruturas de hastes coaxiais e tubos de cobre são colocados neste buracos e separados por fibras de plástico resistente a radiação, como ilustra a Figura 3.7. A matriz e o tubo são o material passivo enquanto os espaços entre o tubo e as hastes com aproximadamente $269 \mu\text{m}$ são preenchidos com LAr que constitui o meio de amostragem. O efeito capacitivo é criado visto que as hastes estão sujeitas a alta tensão e o tubo está aterrado. A primeira camada possui em torno de 2016 canais e 24520 eletrodos.

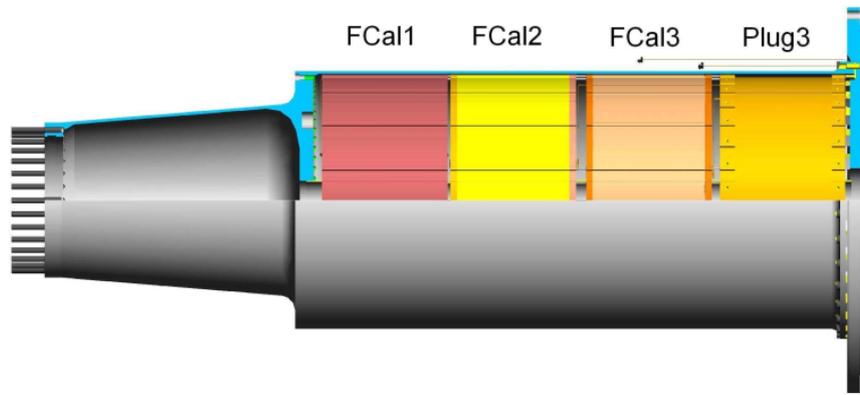


Figura 3.6: Corte lateral do **FCAL** no tubo de suporte do criostato. O ponto de iteração está à esquerda. Da esquerda para a direita estão FCal1, FCal2, FCal3. Extraído de [33]

A segunda (F2CAL) e a terceira (F3CAL) possuem módulos hadrônicos mais densos que utilizam tungstênio como material absorvedor. A Figura 3.8 mostra a estrutura do eletrodo que consiste em um tubo de cobre que contém uma haste de tungstênio com um ânodo encaixado na sua extremidade. Os eletrodos são cercados por um grande número de peças de tungstênio que preenchem o espaço entre os tubos em um padrão hexagonal, esta estrutura é mostrada à direita na Figura 3.8.

A segunda camada possui um *gap* de $376 \mu\text{m}$ preenchidos com LAr, 20400 eletrodos e em torno de 1000 canais. A terceira camada possui uma fissura com aproximadamente $508 \mu\text{m}$ preenchida com LAr, 16448 eletrodos e aproximadamente 508 canais.



Figura 3.7: Ilustração da frente do módulo FCal1 durante a sua construção. Extraído de [33]

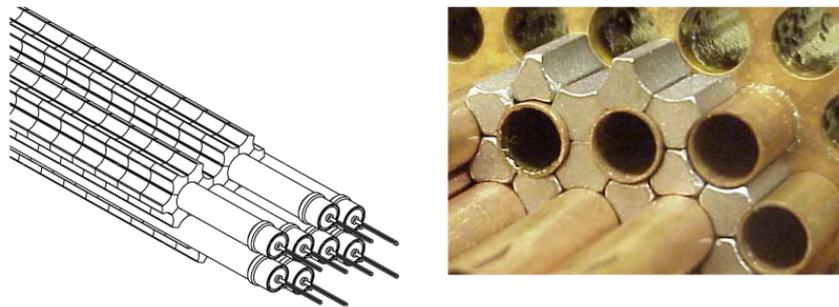


Figura 3.8: À esquerda: desenho do esquema da seção hadrônica do FCAL mostrando as hastes e os ânodos de cobre. Na imagem à direita temos uma foto ilustrando o arranjo entre as peças de tungstênio ao redor dos eletrodos de cobre. Extraído de [33]

3.4 Sistema de Trigger

O **Trigger e Sistema de Aquisição de Dados (TDAQ)** [56–58] é uma parte fundamental do experimento **ATLAS** uma vez que realiza o processamento *online* e decide sobre o armazenamento de dados de uma determinada colisão. O experimento **ATLAS** produz um volume enorme de informação a cada colisão. A taxa de eventos gerados é de 40 MHz, cada evento carrega no máximo 1,5 MB de informação desta forma o fluxo de dados é da ordem de 60 TB/s [59], o que inviabiliza o armaze-

namento pleno dos dados gerados no experimento e torna indispensável a existência de sistema de filtragem *online* para a análise posterior dos eventos (*offline*), esta decisão tem um grande impacto nos dados que são utilizados para análises físicas.

O TDAQ (Figura 3.9) é responsável pelo processamento, seleção e armazenamento de eventos de interesse para análises *offline*. A seleção de eventos é realizada a partir do sistema de Trigger que é dividido em duas etapas. A primeira etapa, chamada de Primeiro Nível de Filtragem (L1) é baseada em *hardware* e capaz de reduzir a taxa de eventos de 40 MHz para 100 KHz selecionando as possíveis regiões de interesse (RoI), com granularidade reduzida, através de cortes em energia.

O segundo estágio do Trigger, o HLT, é baseado em *software*. Um típica sequência de reconstrução utiliza algoritmos rápidos dedicados para evitar a rejeição prematura seguida por outros algoritmos ainda mais precisos e com mais custo computacional para realizar a seleção final que são similares aos utilizados na reconstrução *offline* mas com adaptações necessárias ao ambiente *online*, como as restrições de tempo e processamento. Estes algoritmos são executados em uma *computing Farm* dedicada com aproximadamente 40000 unidades de processamento para seleção de aplicações (PUs). O HLT é baseado no *software Athena*¹ [60], que por sua vez foi inspirado em um *framework* para processamento de dados de física de partículas e altas energias chamado Gaudi. Se um evento for aceito pelo HLT este será enviado para armazenamento permanente e para reconstrução *offline*.

O sistema de filtragem *offline* do ATLAS é responsável por analisar os eventos que foram selecionados pelo sistema *online* e armazenados em disco. Tal sistema é capaz de acessar todos os sinais do detector no momento em que foram produzidos e reconstruí-los com granularidade plena. Como o *offline* não possui a restrição de tempo que é imposta no sistema *online*, torna-se possível a utilização de algoritmos de reconstrução de maior custo computacional para reconstruir o evento com maior precisão e etiquetá-lo com maior acurácia.

¹O *Athena* é *software* desenvolvido pelo ATLAS para as seguintes funções: geração de eventos, simulação, reconstrução, produção de derivações, além de ser utilizado no segundo estágio do Trigger do ATLAS.

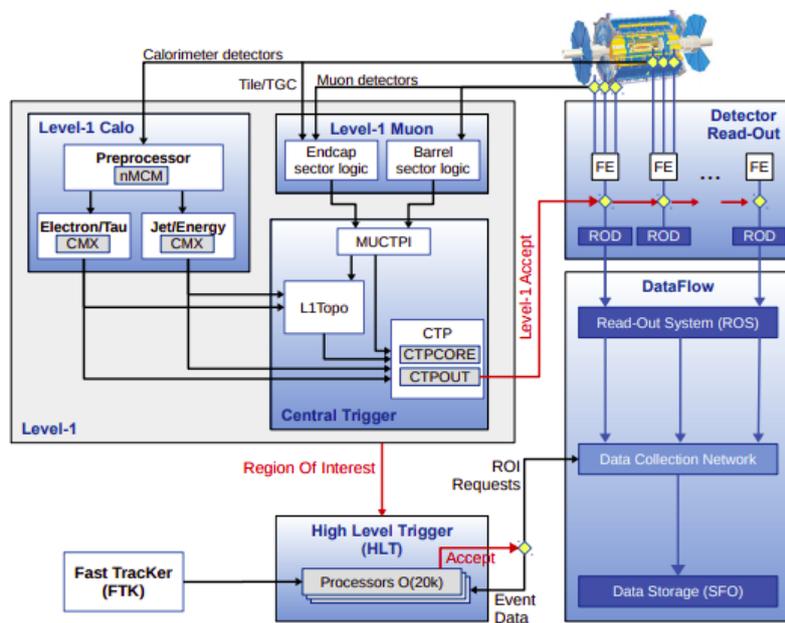


Figura 3.9: O TDAQ do ATLAS em atuação durante a *Run 2*. Extraído de [58]

Capítulo 4

Sistema de Filtragem Online de Elétrons do ATLAS

Os elétrons são partículas elementares que estão presentes em vários processos físicos raros de interesse dentre eles o bóson de Higgs e pesquisas de nova física (*beyond standard model*) como a [Teoria de Supersimetria \(SUSY\)](#) e *dark matter*. A detecção de elétrons é extremamente importante tanto para a identificação destes eventos raros quanto para a operação do experimento, uma vez que os elétrons são utilizados para alinhamento e calibração dos sensores quando a tomada de dados é iniciada. O [ATLAS](#) utiliza um sistema de filtragem de elétrons desenvolvido para lidar com alta taxa de eventos, grande volume de ruído de fundo gerado nas colisões e com o elevado número de canais de leitura proveniente dos detectores. A [Figura 4.1](#) ilustra o fluxo de dados produzidos através do sistema de filtragem online do [ATLAS](#).

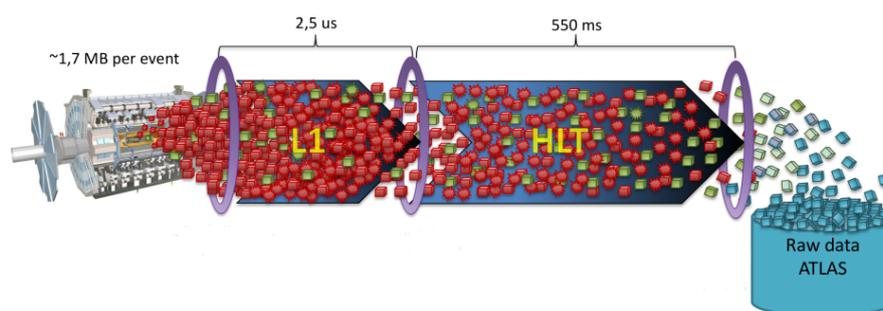


Figura 4.1: Esquema do sistema de filtragem online de elétrons do [ATLAS](#). Adaptado de [\[21\]](#)

O sistema de filtragem online de elétrons do [ATLAS](#) é estruturado hierarquicamente de forma que os níveis superiores validam a decisão dos níveis abaixo. Neste sistema os níveis inferiores aplicam cortes mais simples enquanto os níveis mais altos dispõem de uma maior latência para análise e podem empregar critérios de seleção

mais sofisticados.

4.1 *L1Calo*

O Primeiro Nível de Filtragem para o Sistema de Calorimetria (*L1Calo*) utiliza a informação obtida a partir de um subconjunto de detectores com granularidade reduzida para realizar a seleção inicial. O primeiro nível do Trigger de elétrons utiliza apenas a informação oriunda do sistema de calorimetria, uma vez que o custo computacional necessário para agregar a informação de traços fornecida pelo detector interno seria muito alta. A principal característica do *L1Calo* é a latência. O tempo para tomada de decisão neste nível é da ordem de microssegundos, isto torna fundamental a redução da informação e por este motivo as células dos calorímetros são agrupadas em conjuntos de seis células que tem seus sinais somados analogicamente para produzir apenas um único sinal por conjunto. O sinal resultante é comparado com um limiar de corte de energia que é pré-definido e apenas eventos que possuem características extremamente distintas dos canais de interesse são descartados.

O *L1Calo* é implementado em hardware e utiliza algoritmos complexos e informações como energia, perfil longitudinal e lateral do evento para realizar a filtragem de elétrons. Este algoritmo realiza o processamento a partir de janelas deslizantes que separam as regiões de RoI no sistema de calorimetria.

O *L1Calo* utiliza torres de Trigger (Torre de Filtragem (TT)) com granularidade de $0,1 \times 0,1$ em $\eta \times \phi$ ao longo de todo calorímetro para realizar uma busca pela máxima energia medida na região do calorímetro eletromagnético em uma janela 2×2 contida em uma janela de 4×4 no ECAL [9, 58]. Quando a RoI é encontrada um corte em η e E_T é aplicado. A Figura 4.2 apresenta o esquema utilizado pela janela deslizante no *L1Calo* para seleção de elétrons. Todavia existem mais três outros testes que podem ser avaliados para seleção de elétrons [61] e que são aplicados sequencialmente, são eles:

- **Isolamento Eletromagnético (EM_{isol}):** Se o valor resultante da soma da energia transversa de 12 torres eletromagnéticas posicionadas ao redor dos quatro *clusters* eletromagnéticos for inferior ou igual ao patamar de decisão estabelecido este critério é aprovado.
- **Isolamento Hadrônico (HAD_{isol}):** Para o caso em que o valor resultante da soma da energia transversa de 12 torres hadrônicas posicionadas ao redor do núcleo hadrônico for menor ou igual ao patamar de decisão estabelecido este teste é aprovado.
- **Núcleo hadrônico (HAD_{core}):** Quando a soma das quatro torres do calorímetro

hadrônico, posicionadas atrás dos *clusters* eletromagnéticos, for menor ou igual a um determinado patamar este teste é aprovado.

Se porventura a *RoI* for aprovada em todos os critérios pré-estabelecidos, a mesma será etiquetada e enviada ao *HLT*.

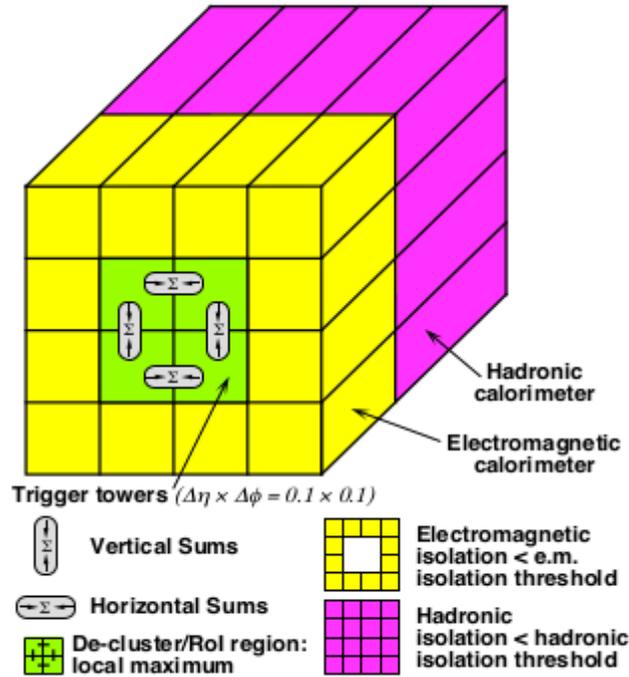


Figura 4.2: Torres de filtragem utilizadas para a seleção de elétrons no *L1Calo* do *ATLAS*. Extraído de [61]

4.2 HLT

O *Trigger* de alto nível é dividido em duas etapas, como ilustra a Figura 4.3: a etapa rápida e a etapa precisa. Na primeira etapa algoritmos de reconstrução com baixa latência são empregados para reduzir o número de eventos sem relevância no início da cadeia. Os eventos que forem aprovados nesta etapa seguem para a etapa precisa, onde é realizada a calibração de energia das células e a reconstrução das informações de traço e calorimetria. Se um dado elemento for aprovado pelo algoritmo de seleção a cadeia sinaliza o sistema de *Trigger* e todo o evento pertencente àquela *RoI* é salvo em disco.

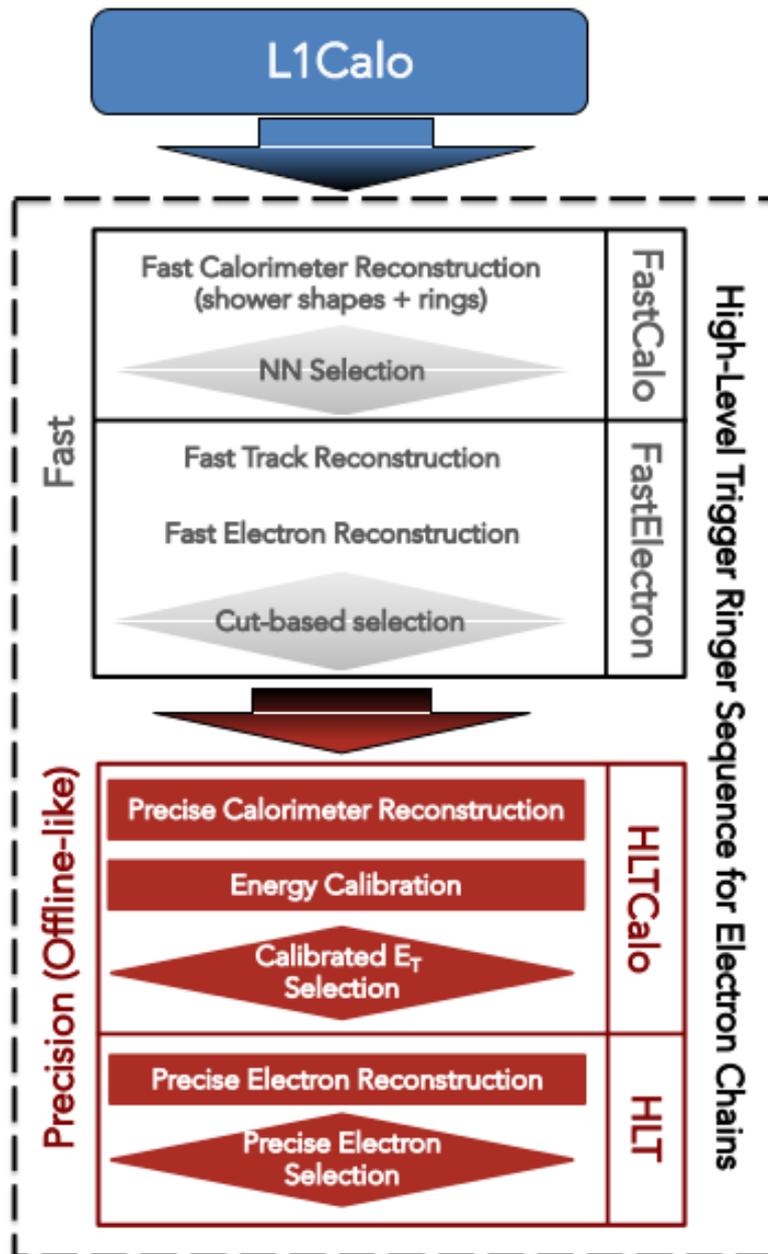


Figura 4.3: Fluxograma empregado para seleção de elétrons no HLT do ATLAS durante o período de 2017 e 2018 para elétrons com $E_T > 15$ GeV. Extraído de [26]

4.2.1 Reconstrução rápida do calorímetro e etapa de pré-seleção

A reconstrução rápida das cadeias de identificação de elétrons é executada pelo Algoritmo de Extração de Característica (FEX) baseado na informação de calorimetria. A partir de células da segunda camada do calorímetro eletromagnético (EM2) o algoritmo aperfeiçoa a medida da posição da RoI em relação a $\eta \times \phi$ por meio

do cálculo do seu baricentro. Ulteriormente, o [FEX](#) inicia o processo de reconstrução de um conjunto de variáveis físicas extremamente discriminantes baseadas na informação de calorimetria. As principais grandezas calculadas nesta etapa são:

- Vazamento em η (R_η): é expresso pela seguinte Equação (4.1) medida na segunda camada eletromagnética. Nesta $E_{m \times n}$ é a energia depositada numa região de $m \times n$ células ao redor da célula mais quente.

$$R_\eta = \frac{E_{3 \times 7}}{E_{7 \times 7}} \quad (4.1)$$

- (E_{ratio}): é definida como a razão entre a diferença de energia do maior e do segundo maior depósito de energia e a soma destes na primeira camada do calorímetro eletromagnético ([EM1](#)), como mostra a Equação (4.2).

$$E_{ratio} = \frac{E_{max,1}^{S1} - E_{max,2}^{S1}}{E_{max,1}^{S1} + E_{max,2}^{S1}} \quad (4.2)$$

- Energia transversa eletromagnética (E_{EM1}): é a energia transversa total que foi depositada nas três camadas do calorímetro eletromagnético ([EM1](#), [EM2](#), [EM3](#)) ao redor da célula mais quente na camada [EM2](#) numa região contendo 3×7 células.
- Vazamento hadrônico (R_{had}): é a razão entre a energia transversa medida no [HCAL](#) e a energia transversa medida no [ECAL](#), conforme a Equação (4.3).

$$R_{had} = \frac{E_T^{had}}{E_T^{EM}} \quad (4.3)$$

- Anéis de energia (*Rings*): os anéis são construídos a partir da posição em $\eta \times \phi$ da célula mais quente na segunda camada eletromagnética ([EM2](#)), esta célula constitui o primeiro anel. O segundo anel é construído mediante a soma da energia das células adjacentes ao primeiro anel. O processo segue por meio da extrapolação da célula mais quente da [EM2](#) para as demais camadas e esta técnica é repetida até que seja obtido um número predefinido de anéis por camada.

Mediante a reconstrução das variáveis citadas acima, o [Algoritmo de Hipótese \(HYPO\)](#) é inicializado pelo sistema de filtragem. Este algoritmo baseia-se em parâmetros de cortes que estão associados ao tipo de objeto físico, a região do calorímetro, o ponto de operação da cadeia do [Trigger](#) e a região de energia do *cluster*. No *RunII*, o [ATLAS](#) aplicou duas estratégias para a tomada de decisão, são elas o *CutBased* e o algoritmo *NeuralRinger*.

4.2.1.1 *CutBased*

O *CutBased* opera através da aplicação de uma sequência de cortes nas variáveis de calorimetria para a região $E_T > 15$ GeV. Especificamente o *CutBased* aplica cortes sequenciais nas variáveis R_η , E_{ratio} , $E_{T,EM}$ e R_{had} , seguindo respectivamente a ordem em que foram citadas. Os cortes são subdivididos em três regiões de E_T ($E_T < 12$ GeV, $12 \leq E_T < 22$ GeV e $E_T \geq 22$ GeV) e nove regiões de η (Tabela 4.1).

Tal estratégia de seleção foi utilizada apenas para cadeias de baixa energia com $E_T < 15$ GeV e para algumas cadeias duplicadas para $E_T > 15$ GeV. A seleção da região de E_T empregada para a tomada de decisão é obtida através do corte nominal da cadeia a ser processada, entretanto a região de η é obtida da posição do candidato.

$ \eta $	0,0	0,6	0,8	1,15	1,37	1,52	1,81	2,01	2,37	2,47
----------	-----	-----	-----	------	------	------	------	------	------	------

Tabela 4.1: Fronteiras de η adotadas para o *ensemble* de cortes do ATLAS na etapa de pré-seleção rápida.

4.2.1.2 *NeuralRinger*

O *NeuralRinger* é uma abordagem multivariável baseada em redes neurais que foi adotada a partir de 2017 para $E_T > 15$ GeV e $\eta < 2,5$ ¹. Esta estratégia demonstrou grande capacidade de discriminação de elétrons e redução da taxa de falsos positivos utilizando apenas informação anelada de calorimetria (*Rings*) [10, 26].

4.2.1.2.1 Informação anelada de calorimetria

A estrutura do chuveiro gerado pela interação de partículas eletromagnéticas com o material do detector é aproximadamente cônica e assemelha-se ao formato de um lápis (comumente referido pelo termo em inglês *pencil-like*) e difere-se neste aspecto do chuveiro gerado por partículas hadrônicas que é mais amplo ao longo do seu desenvolvimento longitudinal, como podemos notar através da Figura 4.4. Desta forma, algumas grandezas físicas são extremamente importantes para a caracterização dos chuveiros e a identificação destas partículas, dentre elas a largura lateral e longitudinal do chuveiro [18].

Os anéis concêntricos de deposição de energia nos calorímetros são outro método eficiente para descrever os chuveiros eletromagnéticos [24]. A informação anelada é composta pela soma da energia das células de uma região delimitada do calorímetro de forma a manter a representação da largura lateral do chuveiro. Os anéis

¹A partir da *Run3* o *NeuralRinger* também será o algoritmo padrão para decisão da etapa rápida de calorimetria para as cadeias com $E_T < 15$ GeV [22].

concêntricos de deposição de energia nos calorímetros são outro método eficiente para descrever os chuviros eletromagnéticos. A informação anelada é composta pela soma da energia das células de uma região delimitada do calorímetro de forma a manter a representação da largura lateral e caracterizar a largura longitudinal do chuviro. Isto permite a caracterização do chuviro numa dimensão menor do que a reconstrução total das células de leitura do calorímetro [10].

A estratégia de anelamento do [ATLAS](#) abrange toda a [RoI](#) de $0,4 \times 0,4$ ($\eta \times \phi$) totalizando 100 anéis. Dessarte os anéis de energia concêntricos (*rings*) fornecem a redução da dimensionalidade do espaço de entrada de 1000 a 1200 células por [RoI](#) para 100 anéis compactando a informação de calorimetria. O algoritmo responsável pelo anelamento da informação de calorimetria utilizado no experimento [ATLAS](#) é descrito com mais detalhes em [21, 26]. A Figura 4.5 ilustra o processo de anelamento do [ATLAS](#).

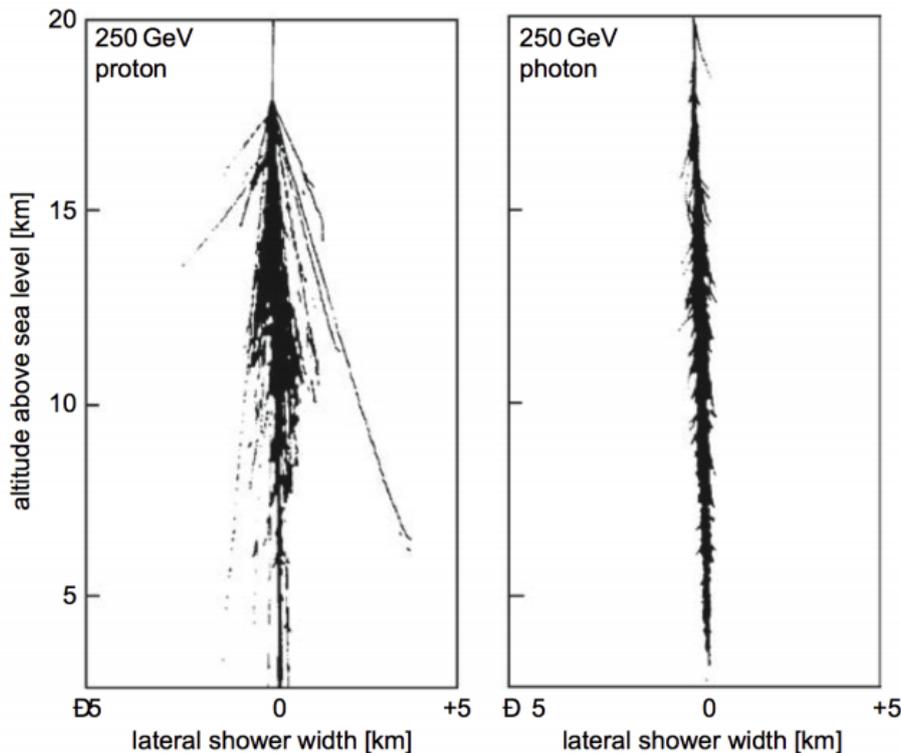


Figura 4.4: Simulação do desenvolvimento dos chuviros hadrônico e eletromagnético na atmosfera terrestre oriundos da interação de um próton (figura da esquerda) e um fóton (figura da direita) com energia de 250 GeV cada. Extraído de [62]

4.2.1.2.2 Método de filtragem *online* de elétrons

O *NeuralRinger* emprega um *ensemble* de classificadores do tipo [MLP](#) construído de forma a garantir a estatística em função da granularidade e preservar a transição dos materiais que constituem o detector. A escolha por um *ensemble* de modelos especialistas para as regiões de E_T e η é conveniente devido a influência da primeira

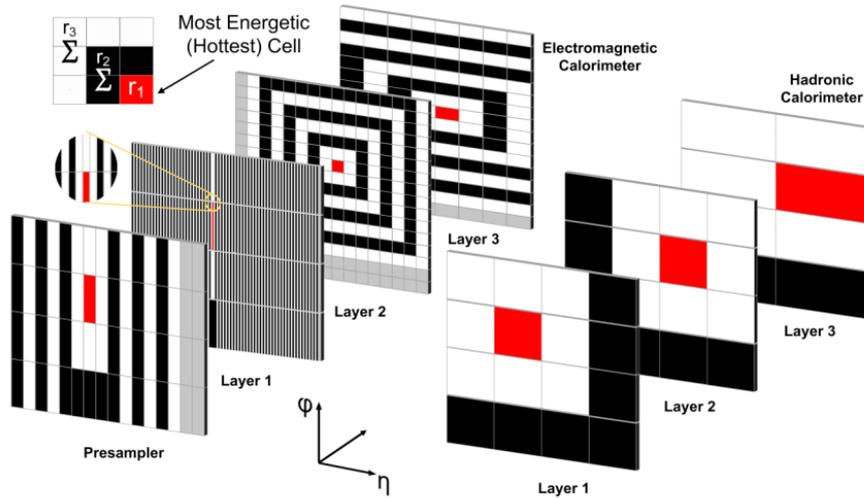


Figura 4.5: Ilustração do processo de anelamento em uma dada região dos calorímetros do [ATLAS](#). Em vermelho destaca-se a célula mais energética que é o primeiro anel construído, os anéis consecutivos são formados pela soma das células presentes na [RoI](#). Extraído de [\[10\]](#)

variável no desenvolvimento do chuveiro e das mudanças relativas a instrumentação do calorímetro que podem ser expressas em termos da segunda variável mencionada e principalmente do impacto da limitação destes espaços de fase para tomada de decisão pelo modelo neural. A Tabela [4.2](#) apresenta as regiões em η e E_T empregadas para a construção do *ensemble* de modelos [MLP](#).

Tabela 4.2: Fronteiras para as regiões em η e E_T empregados pelo *ensemble* de redes neurais acima de 15 GeV. Na tabela K representa o valor máximo da energia de centro de massa obtida durante as colisões no [LHC](#). Adaptado de [\[26\]](#)

Regiões do <i>ensemble</i> e patamares de corte					
Fronteira das Regiões em E_T [GeV]					
15	20	30	40	50	K
Fronteiras das Regiões em $ \eta $					
$0 \leq \eta < 0,8$				Barril	
$0,8 \leq \eta < 1,37$				Barril Estendido	
$1,37 \leq \eta < 1,54$				Crack	
$1,54 \leq \eta < 2,37$				Tampa	
$2,37 \leq \eta < 2,5$				Final da Tampa	

O *NeuralRinger* é constituído por 25 modelos neurais do tipo [MLP](#) que abrangem a região de $E_T > 15$ GeV e $\eta < 2,5$ e atuam de forma independente para cada região do espaço de fase e tomam a decisão a partir apenas da informação anelada de calorimetria (*Rings*). A topologia utilizada para o treinamento dos modelos inclui 1 camada escondida com 5 neurônios com função de ativação tangente hiperbólica e

um neurônio na camada de saída também com a tangente hiperbólica como função de ativação. Durante a operação a função de ativação da camada de saída é substituída (sem alteração dos pesos obtidos após o treinamento) por uma função linear com objetivo de ajustar a eficiência do classificador em função do *pile-up*, conforme descrito em detalhes na seção 5.2.1.

O pré-processamento foi realizado a partir da normalização das entradas² pela divisão do valor de cada anel pelo somatório de todos os anéis. As amostras de sinal utilizadas no treinamento foram provenientes do decaimento do bóson Z em um par elétron-pósitron selecionadas a partir do método *Tag and Probe* (T&P) enquanto as amostras de *background* são compostas por candidatos reprovados pelo T&P para o decaimento do bóson Z .

O algoritmo *Resilient Back-propagation* (RPROP) [63] foi aplicado com objetivo de obter uma rápida convergência e os pesos foram iniciados conforme citado em [64]. A validação cruzada [65] foi empregada através do método *jack-knife*. No total 100 inicializações foram realizadas com objetivo de evitar mínimos locais. Detalhes sobre a seleção e desenvolvimento do *NeuralRinger* encontram-se em [26].

4.2.2 Reconstrução rápida do traço e seleção de elétrons

Na etapa de reconstrução rápida de traços o *Fast Tracker* (FTK) (desenvolvido em hardware e implementado a partir da *Run2*) é utilizado para encontrar candidatos a traço com latência máxima de aproximadamente $70 \mu\text{s}$. O FTK aplica técnicas de reconhecimento de padrões para obter a trajetória das partículas candidatas nas **RoI** avaliadas. Para cada possível partícula são aplicados cortes nas seguintes variáveis:

- $\Delta\eta$: corresponde a diferença entre a posição em relação a η da partícula e a posição em η da **RoI**. Quando este valor é inferior a um limite pré-estabelecido a partícula é rejeitada.
- $\Delta\phi$: esta variável é calculada conforme a citada anteriormente substituindo η pela posição em relação a ϕ . Da mesma forma, se esta diferença for menor que um determinado valor, o candidato é descartado.
- $P_{T,cut}$: representa um corte em relação ao momento transversal do candidato dado um limiar configurado pela *chain*. Se o valor do momento for inferior ao designado a partícula é descartada.
- $\frac{E_T}{p_T}$: é a razão entre a energia transversal da **RoI** medida na etapa rápida de calorimetria e o momento transversal do candidato. Se o resultado obtido for discrepante em relação ao limite pré-estabelecido o candidato é rejeitado.

²As entradas correspondem a um vetor composto por 100 anéis de energia (*Rings*).

Se candidatos forem aprovados pelos cortes citados anteriormente a etapa de precisão é iniciada, caso contrário a **RoI** é descartada.

4.2.3 Etapa precisa do **HLT**

A etapa precisa dispõe de técnicas multivariadas para calibrar a energia das células balizadas pela região do *cluster* [66] com intuito de tornar a medida de energia mais precisa. Posteriormente é realizada a etapa de reconstrução, onde a energia transversa é calculada para as camadas eletromagnéticas, em seguida é realizado um corte de energia designado previamente pela cadeia. Quando o valor de E_T medido é inferior ao patamar pré-estabelecido o processo é finalizado, senão a etapa de reconstrução prossegue.

Enfim, após a calibração, a etapa de reconstrução precisa dos traços é iniciada. Esta etapa busca o casamento (*match*) do candidato a traço com o chuveiro no **ECAL**, o que indica que a partícula pode ser um elétron. Posteriormente as grandezas físicas de calorimetria e traços listadas na Tabela 4.3 são calculadas (com exceção da variável relacionada a perda de momento transverso por *bremsstrahlung*³ $\Delta p/p$ que está disponível apenas durante a reconstrução *offline*). Se o candidato for aprovado pelo **HYPO** a toda a informação produzida pelo evento será salva em disco para análise *offline*.

Na etapa precisa, o **HYPO** realiza a seleção de elétrons através da *likelihood* [67], esta é a mesma técnica que é aplicada para a identificação *offline* com adaptações às restrições de tempo e memória associadas ao ambiente *online*. A *likelihood* do **ATLAS** estima as funções de densidade e probabilidade marginais para as grandezas físicas utilizadas para a seleção (descritas na Tabela 4.3) a partir da **Estimação de Densidade por Kernel (KDE)** gaussiano [67] para o sinal (elétron) e para o *background* (jato) mediante a suposição de que as variáveis são independentes entre si. A combinação das probabilidades para elétron e jato geram um discriminante, dado pela Equação 4.4.

$$d_L = \frac{L_S}{L_S + L_B}, \quad L_{S(B)}(\vec{x}) = \prod_{i=1}^n P_{S(B),i}(x_i) \quad (4.4)$$

onde \vec{x} é representado pelas variáveis discriminantes da Tabela 4.3 e $P_{S,i}(x_i)$ é o valor da *pdf* referente ao sinal (elétron) da i -ésima variável dada por x_i . Da mesma forma, $P_{B,i}(x_i)$ refere-se ao valor da *pdf* para o ruído (jato).

A adoção da *likelihood* na etapa precisa, em virtude do aumento do empilha-

³O *bremsstrahlung* (radiação de frenagem) é o processo no qual uma partícula carregada ao atravessar a matéria perde energia pela interação com o campo elétrico de um núcleo através da irradiação de fótons. A radiação de frenagem é uma contribuição particularmente importante para a perda de energia de elétrons e pósitrons. [13]

mento, torna essencial a utilização de um ajuste para manter a eficiência em função do mesmo. O melhor estimador para o empilhamento é o [número de vértices \(*nvtx*\)](#) reconstruídos do evento, tal variável é utilizada pela *likelihood* para realizar tal ajuste. O *NeuralRinger* também executa uma correção em função do empilhamento mas baseado na variável [número médio de interações por cruzamento de pacote \(\$\langle\mu\rangle\$ \)](#), uma vez que este algoritmo atua na etapa rápida de calorimetria e a variável *nvtx* está disponível apenas a partir da etapa precisa do [HLT](#).

Tabela 4.3: Grandezas empregadas pelo ATLAS para discriminação de elétrons. Extraído de [26].

Tipo	Descrição	Nome
Vazamento Hadrônico	Razão em E_T da primeira camada do calorímetro hadrônico para a E_T do <i>cluster</i> EM (empregado para a região $ \eta < 0,8$ ou $ \eta > 1,37$)	R_{had1}
	Razão em E_T no calorímetro hadrônico para a E_T a E_T do <i>cluster</i> EM (empregado para a região $0,8 < \eta < 1,37$), dada em (4.3)	R_{had}
Região Traseira do Calorímetro EM	Razão de energia da camada traseira para a energia total do calorímetro de acordeão EM. Essa variável é somente empregada abaixo de 100 GeV pois se sabe que ela é ineficiente em altas energias.	f_3
Camada Central do Calorímetro EM	Largura lateral do chuveiro, $\sqrt{(\sum E_i \eta_i^2)/(\sum E_i) - ((\sum E_i \eta_i)/(\sum E_i))^2}$, onde E_i é a energia e η_i a pseudorapidez da célula i e a soma é calcula dentro de uma janela com 3×5 células.	$w_{\eta 2}$
	Razão de energia em 3×3 células para a energia em 3×7 células centradas na posição do <i>cluster</i> do elétron	R_ϕ
	Razão de energia em 3×7 células para a energia em 7×7 células centradas na posição do <i>cluster</i> do elétron, dada em (4.1)	R_η
Camada de Tiras do Calorímetro EM	Largura do chuveiro, $\sqrt{(\sum E_i (i - i_{max})^2)/(\sum E_i)}$, onde i percorre todas as tiras na janela $\Delta\eta \times \Delta\phi \approx 0,0625 \times 0,2$, correspondendo tipicamente a 20 tiras em η . i_{max} é o índice da tira com a maior deposição de energia.	w_{stot}
	Razão de energia da diferença entre os depósitos de maior e a de segunda maior energia no <i>cluster</i> para a soma dessas energias, dada em (4.2)	E_{ratio}
	Razão da energia na camada de tiras para o total de energia no acordeão EM do calorímetro.	f_1
Condições do Traço	Número de pontos na camada mais interna de pixel; discriminante contra conversões de fótons.	n_{blayer}
	Número de pontos no detector de pixel.	n_{pixel}
	Número total de pontos nos detectores de pixel e SCT.	n_{Si}
	Parâmetro transverso do ponto de impacto em relação ao feixe de colisão	d_0
	Significância do parâmetro transverso do ponto de impacto definido como a razão de d_0 e sua incerteza	d_0/σ_{d_0}
	Perda de momento do traço entre o ponto originário e final de medida divididos pelo momento original	$\Delta p/p$
TRT	Probabilidade de verossimilhança baseada na radiação de transição no TRT	eProbabilityHT
	Transformação em eProbabilityHT: $TRT_PID = -\frac{\log((1.0/eProbabilityHT)-1.0)}{15}$	TRT_PID
Casamento <i>cluster</i> -traço	$\Delta\eta$ entre a posição do <i>cluster</i> na camada de tiras e o traço extrapolado	$\Delta\eta_1$
	$\Delta\phi$ entre a posição do <i>cluster</i> na camada central e o traço extrapolado do ponto originário	$\Delta\phi_2$
	Definido como $\Delta\phi_2$, mas o momento do traço é reescalado para a energia do <i>cluster</i> antes de extrapolar o traço do ponto originário até a camada central do calorímetro	$\Delta\phi_{res}$
	Razão da energia do <i>cluster</i> para o momento do traço	E/p

4.3 Estratégias de identificação de elétrons para regiões de alta pseudorapidez

O sistema de filtragem online do [ATLAS](#) é restrito a região $|\eta| < 2,5$. Posto isto, não existe seleção *online* de elétrons para a região *Forward* do detector sendo necessário realizar a identificação de elétrons *offline* a partir dos eventos que foram salvos pelas cadeias de filtragem que atuam em $|\eta| < 2,5$. Nesta região não existe detectores de traço, assim o candidato a elétron deve ser reconstruído apenas com a energia depositada em um agrupamento (*cluster*) de células nos calorímetros que se baseiam na significância desta energia em relação ao ruído esperado [68]. Estes *clusters* possuem um número variável de células em contraste com o tamanho fixo utilizado na região central [69]. Desta forma a direção do elétron *Forward* é definida pelo baricentro das células que pertencem ao *cluster* e a energia do elétron é dada pelo somatório das energias destas células seguido de uma correção para a energia perdida no material passivo antes do calorímetro. Um candidato à elétron na região *Forward* é reconstruído, se e somente se, possuir uma pequena energia hadrônica e $E_T > 5$ GeV.

A partir da reconstrução do *cluster* é possível definir o seu momento de grau n para uma variável x da seguinte forma:

$$\langle x^n \rangle = \frac{\sum_i E_i x_i^n}{\sum_i E_i} \quad (4.5)$$

onde o somatório abrange todas as células do *cluster*.

A identificação de elétrons na região com $|\eta| > 2,5$ é baseada apenas nos momentos dos agrupamentos (*cluster*) e nas variáveis características do chuveiros de partículas (*shower-shapes*) [70]. Este conjunto de variáveis proporciona a discriminação entre elétron e hádrons devido a boa segmentação longitudinal e transversa dos calorímetros, porém não possibilita a distinção entre elétrons e fótons. O [ATLAS](#) possui dois conjuntos de cortes para identificação de elétrons *Forward*, chamadas de *Forward tight* e *Forward loose*. As variáveis utilizadas no processo de identificação de elétrons *Forward* estão dispostas na Tabela 4.4.

Tabela 4.4: Grandezas empregadas pelo ATLAS para discriminação de elétrons na região *Forward*. As letras (T) e (L) indicam, respectivamente, *Forward tight* e *Forward loose* indicando em qual operação a variável é utilizada, sendo (TL) para quando a variável é utilizada em ambos os critérios. Adaptado de [68].

Tipo	Descrição	Nome
Profundidade do chuveiro (L)	Distância do baricentro do chuveiro a partir da face frontal do calorímetro medida ao longo do eixo do chuveiro	λ_{center}
Segundo momento longitudinal (L)	Segundo momento da distância de cada célula ao centro do chuveiro na direção longitudinal (λ_i).	$\langle \lambda^2 \rangle$
Segundo momento transverso (L)	Segundo momento da distância de cada célula ao centro do chuveiro na direção transversa (r_i).	$\langle r^2 \rangle$
Energia máxima da célula (TL)	Fração de energia do <i>cluster</i> na célula mais energética	f_{max}
Momento lateral normalizado (TL)	Calcula-se o segundo momento para r_i igualando-o à zero para as duas células mais energéticas (w_2) e novamente calcula-se o segundo momento de r_i mas desta vez para duas células mais energéticas faz-se $r_i = 4$ cm e 0 para todas as outras células (w_{max})	$\frac{w_2}{w_2 + w_{max}}$
Momento lateral normalizado (TL)	Calcula-se o segundo momento para λ_i igualando-o à zero para as duas células mais energéticas (l_2) e em seguida calcula-se o segundo momento de λ_i mas desta vez para duas células mais energéticas faz-se $\lambda_i = 4$ cm e 0 para todas as outras células (l_{max})	$\frac{l_2}{l_2 + l_{max}}$

O CMS [71] possui um sistema de filtragem de elétrons semelhante ao do experimento ATLAS, com uma estratégia baseada em etapas, onde o primeiro nível é baseado em *hardware* e o segundo chama-se HLT [72–76]. No primeiro nível, chamado de *Level-1.0*, a taxa de eventos é reduzida para 100kHz. Este nível tem como elementos básicos matrizes de 5×5 em η e ϕ que são combinadas em torres de energia e cobrem a região do barril e das tampas do detector. Na região das tampas, a geometria do detector é diferente mas as torres possuem um *layout* similar ao da região do barril. As torres do *Level-1.0* são responsáveis pela medida de E_T que é somada e enviada para um Trigger que constrói e identifica os candidatos a elétron e fóton através de medidas de energia e isolamento.

O HLT do experimento CMS é implementado em *software* e utiliza uma fazenda de computadores para reduzir a taxa de saída da informação do *Level-1.0*, assim como no ATLAS este algoritmo é uma versão degradada do ambiente de análise *offline*. O sistema de Trigger online de elétrons do CMS é baseado em cortes de variáveis extremamente discriminantes obtidas pelo sistema de calorimetria e detector de traços [77–81]. Não foi encontrado na literatura menção a utilização de redes neurais em ambiente online no sistema de filtragem de elétrons do CMS e nem citação a seleção de elétrons online em regiões de alta pseudorapidez, visto que a identificação de elétrons e fótons no CMS se estende até a região de $|\eta| = 3,0$ [82].

O acelerador Tevatron, localizado no *Fermi National Accelerator Laboratory* (Fermilab), nos Estados Unidos, possuía dois detectores, o *The Collider Detector at Fermilab* (CDF) [83] e o *D0 Experiment* (D0) [84], e operou até 2011. O experimento CDF possuía um sistema de Trigger [85, 86] de três níveis, onde cada nível fornece uma redução de taxa suficiente para o processamento do próximo nível. A Figura 4.6 ilustra o sistema de Trigger para o experimento. Os dois primeiros níveis do sistema de seleção são baseados em *hardware* e o último nível é composto por um *software* de seleção que é processado em uma fazenda de computadores *Linux*. O nível 1 utiliza um *hardware* customizado para encontrar objetos físicos baseado num subconjunto do detector. O *hardware* consiste do processamento síncrono e paralelo de três vias: uma para identificar objetos baseados em calorimetria, outro para identificar múons e uma terceira faz o rastreamento dos traços. Se um evento é aceito pelo nível 1 do Trigger, os dados são movidos para o nível 2.

O nível 2 faz uma reconstrução limitada através de um *hardware* que contém vários subsistemas que encontram regiões de interesse (*clusters*) a partir da informação de calorimetria. Para a identificação de elétrons e fótons a informação do detector *Shower Maximum Detector* [87] é utilizada para aperfeiçoar as medidas. O Trigger no nível 2 aceita em torno de 300 eventos por segundo, estes são transferidos para a fazenda de processamento do nível 3. Na fazenda de processamento os eventos são reconstruídos e filtrados utilizando algoritmos de reconstrução *offline* e são salvos

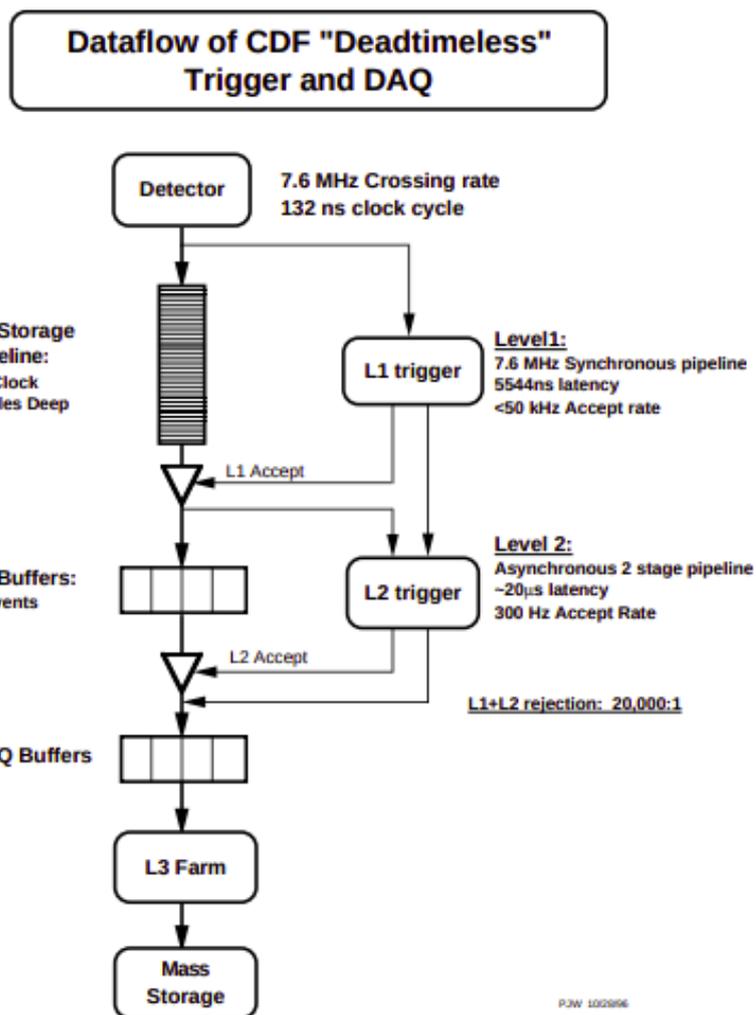


Figura 4.6: Esquema da aquisição de dados e Trigger do experimento CDF. Extraída de [86].

permanentemente no *storage*.

O CDF não possuía um algoritmo específico para seleção online de elétrons na região *Forward* do experimento, entretanto redes neurais artificiais utilizavam variáveis de traços e de calorimetria para a identificação offline de elétrons *Forward* [86]. Esta seleção *offline* favorece as análises físicas de *single-top* e da produção de elétrons a partir do decaimento de bósons W .

O detector $D\emptyset$ também possui um sistema de filtragem *online* de elétrons baseado em níveis [88–91], como podemos ver na Figura 4.7. O primeiro nível possui implementação em *hardware* e são feitos cortes em E_T a partir da informação de traços e calorimetria. Neste estágio a tomada de decisão leva cerca de 4 μs para uma taxa de 10 kHz. O segundo nível tem uma latência de 100 μs reduzindo a taxa para 1 kHz. Esta etapa é implementada em *hardware* e é subdividida em dois estágios distintos: primeiro, são preparados os dados recebidos do nível 1 e na etapa seguinte

são feitas combinações de informações provenientes dos subsistemas do detector e a decisão é tomada a partir de cortes baseados em correlação, energia, etc. O terceiro e último nível realiza a leitura de todo o detector a partir dos eventos aprovados nos níveis 1 e 2, isto aumenta a rejeição aos eventos de fundo.

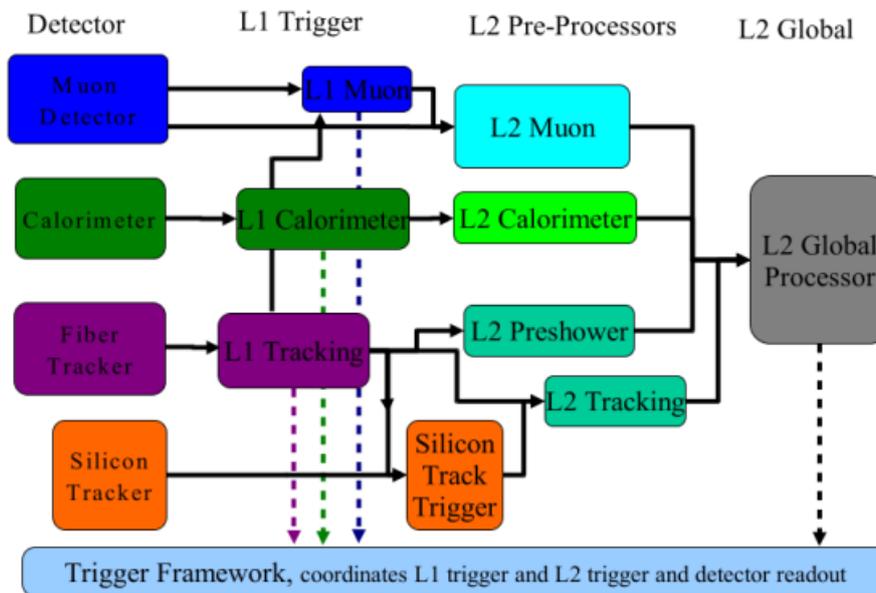


Figura 4.7: Ilustração do esquema de Trigger do experimento D0. Extraída de [88].

Não foi encontrado na literatura nenhuma menção sobre um sistema de filtragem *online* para elétrons na região *Forward*, nem sobre a utilização de redes neurais artificiais no ambiente *online*. Entretanto, existem estudos que apontam a utilização de modelos neurais para identificação *offline* de elétrons a partir da informação de calorimetria, em particular de depósitos observados nas cinco primeiras camadas do calorímetro e quatro *bins* radiais sobre o pico do chuveiro de partículas para 0.1 ($\delta\eta$, $\delta\phi$) [40, 92].

Capítulo 5

Método

Neste capítulo serão descritos os aspectos relativos a seleção de amostras, o pré-processamento para redução sintética de granularidade com o objetivo de emular o comportamento da região com $|\eta| > 2,5$ a partir da região mais externa em η do barril (veja Tabela 4.2), além do processo de treinamento e avaliação dos modelos neurais. A primeira etapa consiste na seleção de amostras através do método **T&P** do bóson Z . Adiante são apresentados os modelos, os respectivos parâmetros de treinamento e os pontos de operação que foram ajustados de acordo com o **Trigger** e tendo como referência o *CutBased*. Posteriormente os modelos são avaliados e comparados com a versão em operação do *NeuralRinger* ($V8$) e a versão ($V8_F$) que consiste em uma adaptação do $V8$ cujas entradas relativas aos anéis da camada **PS** e **EM3** foram zerados. Por fim é realizada a emulação local do **Trigger** com objetivo de avaliar os modelos numa hipotética operação *online*.

5.1 Seleção de Amostras e Redução Sintética de Granularidade

As amostras de sinal utilizadas neste trabalho foram pré-selecionadas a partir do método **T&P**. Este método é baseado em decaimentos de pares de partículas, como por exemplo: $Z \rightarrow e^+e^-$, $J/\Psi \rightarrow e^+e^-$ e possibilita que a pré-seleção de amostras seja baseada no conhecimento especialista do decaimento sem qualquer influência de discriminadores [93].

O **T&P** do Z exige que exista pelo menos dois candidatos à elétron reconstruídos de forma *offline* no evento. Satisfeito este requisito, inicia-se uma busca por pares de elétrons onde um dos candidatos, chamado de *tag*, é aprovado como elétron pelo *offline* sobre a condição mais restrita (não sendo permitido que o mesmo encontre-se na região de *crack*); enquanto o outro, nomeado de *probe*, precisa atender aos requisitos mínimos com relação a qualidade e a paridade com o *tag* que deve estar

contido no intervalo de massa esperado para o bóson Z , neste caso $80 \text{ GeV} < M_{e^+e^-} < 100 \text{ GeV}$ como descrito em [21, 26]. Atendida estas restrições apenas o *probe* é salvo para posterior análise.

Nas amostras que compõem o *background* é empregado o método T&P inverso. Neste caso, o candidato à elétron *offline* que é selecionado não pode compor quaisquer dos pares *tag* e *probe* proveniente do bóson Z , conforme descrito em [21, 26].

O ATLAS possui diversos grupos de pesquisa, formados por interesses em processos físicos distintos, haja vista que este é um experimento de propósito geral, ou seja, busca estudar toda a física disponível na faixa de energia proporcionada pelo LHC. Isto posto é compreensível que o ATLAS assuma inúmeros critérios para a aquisição de dados. Tais critérios têm o objetivo de garantir o balanceamento entre a qualidade da amostra e a quantidade, visto que, para um determinados grupos que estudam processos físicos muito raros, a quantidade de amostras é fundamental para a realização das análises físicas. Por outro lado, a pureza das amostras pode ser crucial para certas análises em detrimento da quantidade, ou mesmo o equilíbrio entre a pureza e a quantidade podem ser almejados em certos estudos. Posto isto, o ATLAS emprega alguns critérios para identificação de elétrons *offline* (e *online*) visam cobrir satisfazer as diferentes demandas de amostragem, são eles:

- *Tight*: é o critério que prioriza a qualidade da amostra em detrimento da quantidade e apresenta baixos níveis de contaminação.
- *Medium*: é o critério que busca o equilíbrio entre a qualidade da amostra e sua quantidade.
- *Loose*: neste critério é priorizado a quantidade da amostra, o que implica em maiores contaminações.
- *Very Loose*: este é o critério menos restritivo e por isto possui o maior nível de contaminação em suas amostras.

Este trabalho emprega o uso de dados de colisões, especificamente amostras obtidas nos anos de 2017 e 2018. Desta forma, não existe uma etiquetagem das amostras utilizadas para o treinamento dos modelos que compõem o *ensemble* e para contornar isto foram adotados os critérios de amostragem do *offline*.

Assim posto, para as amostras de sinal obtidas pelo método T&P, com objetivo de obter o equilíbrio entre a amostragem e o quantitativo de ruído, a aprovação pelo critério *Medium* do *offline* foi exigida. Para o *background*, pré-selecionado pelo T&P inverso, a aprovação do critério *Very Loose* do *offline* foi imposta.

Devido às restrições do *trigger* não é possível realizar reconstruções à nível *online* para regiões com $|\eta| > 2,5$, uma vez que o *L1Calo* seleciona a *RoI* até $|\eta| < 2,5$.

Posto isso, optou-se pela adaptação sintética das cinco regiões de energia da camada mais externa do *ensemble* do *NeuralRinger*, estas estão listadas na Tabela 4.2. Cada uma das regiões de E_T é construída ao longo das sete camadas de amostragem do sistema de calorimetria, totalizando 100 anéis. Conforme disposto na Tabela 5.1. Com o objetivo de emular o comportamento na região $|\eta| > 2,5$, os anéis relativos as camadas PS e EM3 foram removidos já que não estão disponíveis na região de alta pseudorapidez (Tabela 3.1), logo o número de anéis foi reduzido de 100 para 84, como mostra a Tabela 5.2.

Tabela 5.1: Número de anéis em cada camada do sistema de calorimetria do ATLAS.

Camadas	Secção Eletromagnética				Secção Hadrônica		
	Pre-Sampler	EM1	EM2	EM3	HAD1	HAD2	HAD3
# anéis	8	64	8	8	4	4	4

Tabela 5.2: Número de anéis em cada camada do sistema de calorimetria do ATLAS após a redução de granularidade.

Camadas	Secção Eletromagnética		Secção Hadrônica		
	EM1	EM2	HAD1	HAD2	HAD3
# anéis	64	8	4	4	4

5.2 Modelos Utilizados

Neste trabalho dois tipos de modelos foram desenvolvidos: um modelo MLP e um modelo CNN. No modelo MLP foram testadas algumas variações com relação ao número de neurônios na camada escondida. Foram treinados modelos com 2, 5, 10 e 15, todos com um neurônio na camada de saída, conforme ilustra Figura 5.1.

O modelo CNN utilizado possui camadas convolucionais unidimensionais e uma camada totalmente conectada com 16 neurônios. A camada de saída possui um único neurônio, totalizando 10613 parâmetros treináveis, conforme Figura 5.2. Esta topologia foi desenvolvida para a região do barril do calorímetro e obteve um bom desempenho [26] sendo adaptada para a região textitForward neste trabalho.

A função de ativação para as camadas intermediárias aplicada para cada um dos modelos foi a ReLU [94] enquanto nas camadas de saída foi empregada a função sigmóide. O treinamento utilizou o algoritmo *Adaptive Moment Estimation* (ADAM) [95], os parâmetros que foram aplicados estão dispostos com detalhes na Tabela 5.3. O pré-processamento foi realizado normalizando os anéis pela energia total, de acordo com a Equação (5.1).

$$r'_i = \frac{r_i}{\sum_{j=1}^N r_j} \forall i = 1, 2, \dots, N \quad (5.1)$$

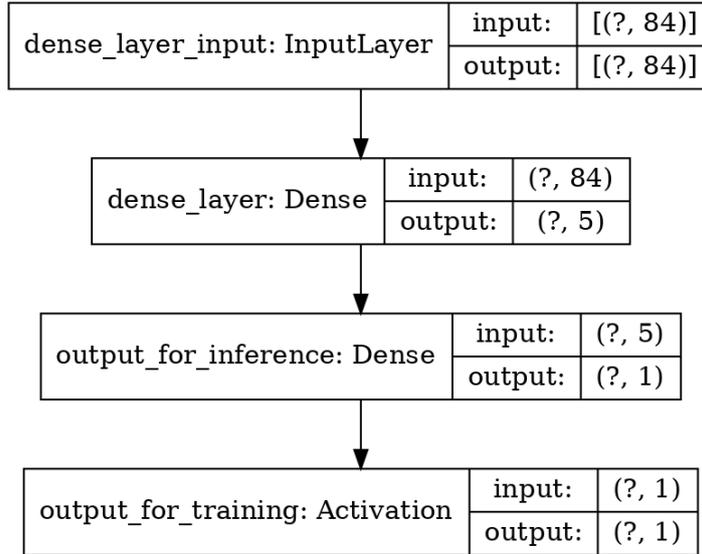


Figura 5.1: Modelo [MLP](#) com 5 neurônios na camada escondida.

onde N é o número de anéis.

Tabela 5.3: Parâmetros do algoritmo [ADAM](#) utilizados no treinamento.

Parâmetros Utilizados no ADAM	
Taxa de Aprendizado (lr)	0,001
β_1	0,9
β_2	0,999

A função objetivo utilizada para o treinamento dos modelos foi o [Erro Quadrático Médio \(MSE\)](#). O [índice soma-produto \(SP\)](#) [96], dado na Equação (5.2), expressa o equilíbrio entre a [probabilidade de detecção de sinal \(\$P_D\$ \)](#) e a [probabilidade de falso alarme \(\$P_F\$ \)](#), o valor máximo desta variável (SP_{\max}) foi adotado como critério de parada do treinamento.

$$SP = \sqrt{\sqrt{P_D(1 - P_F)} \cdot \frac{P_D + (1 - P_F)}{2}} \quad (5.2)$$

Para estimar a incerteza associada aos modelos foi utilizado como método de validação cruzada [65, 97] o *Stratified K-Fold* [97, 98]. Esse método estratifica as classes dentro de cada um dos *folds* o que garante a proporção de cada classe e impede que ocorram casos onde um *fold* não possui dados de alguma das classes.

Os pesos específicos para cada classe foram calculados conforme [99]. Definiu-se $K = 10$ e a partir dos dados de colisão de 2017 foram criados dez *folds*, de forma que 9 foram utilizados para o ajuste dos parâmetros do modelo e 1 foi aplicado como teste. Para cada *fold* foram realizadas 10 inicializações dos pesos com base na técnica de inicialização uniforme de Xavier [100] para evitar um possível mínimo local. O número máximo de épocas em cada inicialização foi de 5000 e o tamanho da batelada

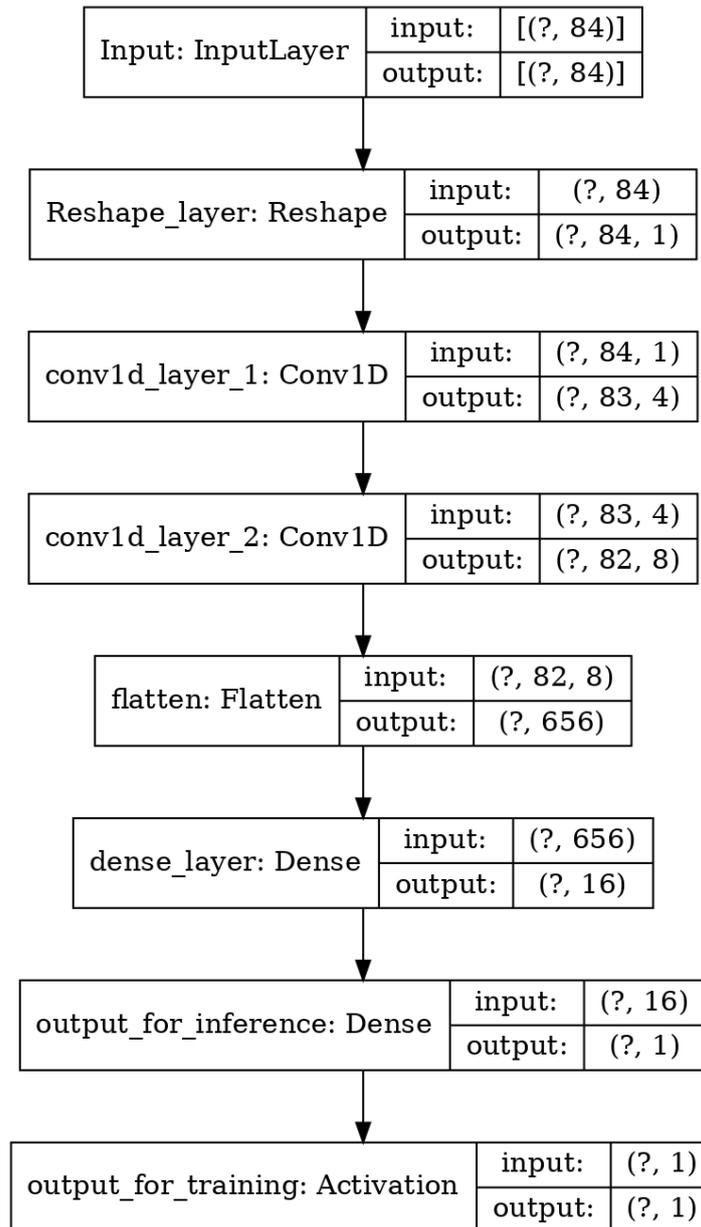


Figura 5.2: Ilustração do modelo CNN com a quantidade parâmetros em cada camada.

foi de 1024 eventos. Este processo é repetido para cada modelo até que todos os dados participem do conjunto de teste ao menos uma vez. Finalizado o processo de treinamento, com base no *SP* do conjunto de teste, a melhor inicialização de cada *fold* é mantida e são calculadas as eficiências dos modelos em cada região do *ensemble*, bem como a incerteza estatística associada.

Os modelos MLP foram testados com diferentes configurações de neurônios na camada escondida. A escolha da melhor configuração para a MLP foi feita avaliando o *SP* medido no processo de validação cruzada para os conjuntos de teste com o auxílio de diagramas de caixa (*boxplots*) e priorizando o maior valor obtido para o índice *SP*, considerando a incerteza estatística de cada modelo. Quando o desem-

penho dos modelos era similar optava-se pelo modelo com a menor complexidade (critério de parcimônia). Após a finalização do processo de treinamento dos modelos é necessário ajustá-los em relação a referência *CutBased* para que atendam aos pontos de operação do *trigger*.

5.2.1 Ajuste em Função de $\langle\mu\rangle$

O aumento da luminosidade leva à maior ocupação do detector o que afeta a reconstrução das partículas, tal processo é conhecido como empilhamento de sinais (*pile-up*). Este é um efeito que afeta os elétrons, descaracterizando os chuveiros eletromagnéticos e tornando-os mais parecidos com chuveiros hadrônicos.

Para mitigar este problema o *ATLAS* realiza um ajuste linear da eficiência em função do estimador de *pile-up*. Este ajuste é feito a partir do método do χ^2 [101]:

$$\chi^2 = \frac{(y - f(x))^2}{e_y^2 + (0,5 \cdot (e_{xl} + e_{xh}) f'(x))^2} \quad (5.3)$$

onde $f(x)$ é a função linear a ser ajustada; e_y é o erro no eixo das ordenadas e e_{xl} (e_{xh}) é o erro no eixo das abscissas.

Para realizar este ajuste é necessário remover a não-linearidade presente nas camadas de saída dos modelos para evitar colapsos quando $\langle\mu\rangle$ tiver valores elevados, conforme ilustra Figura 5.3. Após a remoção da não-linearidade são utilizados os mesmos *folds*, o ajuste é realizado utilizando o conjunto de treino e uma nova medida da incerteza associada aos modelos é feita para o conjunto de teste.

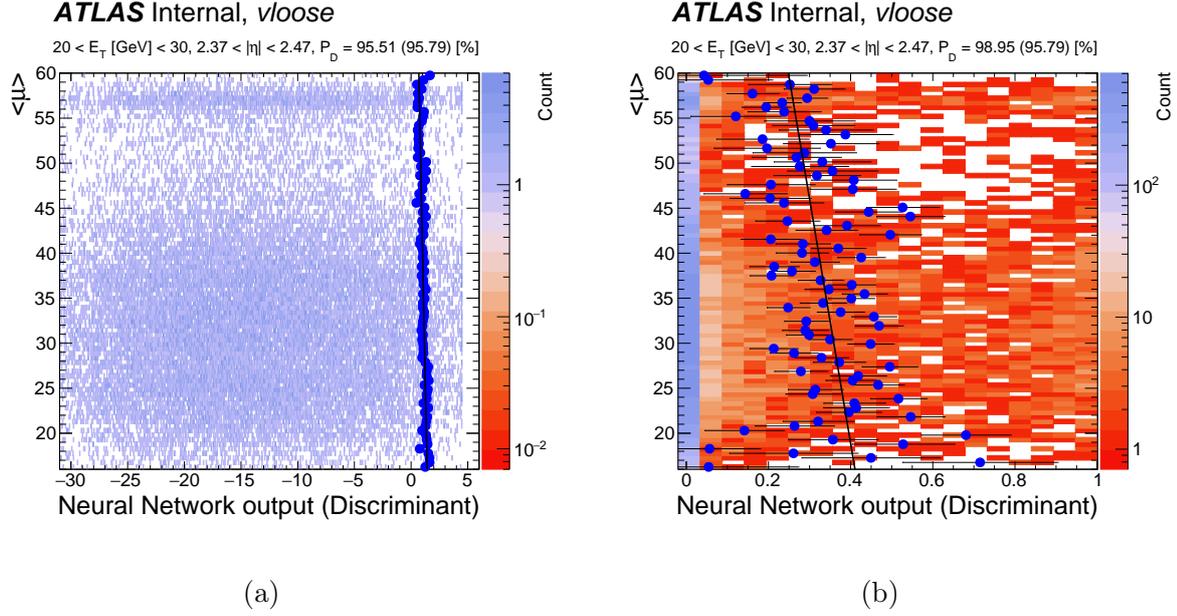


Figura 5.3: Saída do modelo MLP com 5 neurônios em função de $\langle \mu \rangle$. Os pontos azuis indicam os patamares de corte para cada valor de $\langle \mu \rangle$ para que seja obtido o P_D da referência. A linha preta indica o ajuste linear obtido para os patamares. Na Figura (a) temos o ajuste realizado no modelo sem a sigmóide enquanto a Figura (b) o modelo utiliza a sigmóide na camada de saída.

5.3 Seleção e Avaliação dos Modelos

Para cada região de E_T foram gerados 10 modelos, mediante o processo de validação cruzada, o que torna necessário a adoção de um critério para escolher qual seria o melhor modelo dentre estes. A escolha foi feita a partir do maior valor do SP medido no conjunto de treinamento considerando os 10 *folds*.

A partir da seleção dos modelos (1 modelo MLP e 1 modelo CNN), foi avaliado se as saídas produzidas pelos mesmos eram distintas das obtidas pela versão $V8_F$ do *NeuralRinger*. Para isto foi utilizado o teste estatístico de Wilcoxon [102, 103] com a aproximação Normal e nível de significância de 1% ($\alpha = 0.01$) sob as seguintes hipóteses:

$$\left\{ \begin{array}{l} H_0 : \text{A diferença entre as saídas segue uma distribuição} \\ \text{simétrica em torno de zero;} \\ \\ H_1 : \text{A diferença entre as saídas não segue uma distribuição} \\ \text{simétrica em torno de zero.} \end{array} \right. \quad (5.4)$$

A partir da aproximação Normal, é possível calcular o P -value como:

$$P\text{-value} = 2 \cdot P(W' < W'_{\text{calculado}}) \quad (5.5)$$

onde W' é a aproximação do valor da estatística do teste para grandes amostras, dada pela Equação (5.6).

$$W' = \frac{\sum_{i=1}^n Z_i R_i - \frac{n(n+1)}{4}}{\sqrt{\frac{n(n+1)(2n+1)}{24}}} \quad (5.6)$$

Desta forma é possível negar a hipótese H_0 quando o P -value for menor do que α .

Além do teste de Wilcoxon também foi utilizado o teste de McNemar [104] com a correção de continuidade proposta em [105] e o nível de significância $\alpha = 0.01$. O objetivo era verificar qual dos modelos performa melhor nas condições impostas pelo Trigger. As hipóteses a serem testadas são:

$$\begin{cases} H_0 & : \text{Nenhum dos modelos performa melhor do que o outro;} \\ H_1 & : \text{A performance dos modelos é diferente.} \end{cases} \quad (5.7)$$

A estatística do teste de McNemar é dada na Equação (5.8) e segue aproximadamente uma distribuição χ^2 com 1 grau de liberdade.

$$\chi^2 = \frac{(|C_{0,1} - C_{1,0}| - 1)^2}{(C_{0,1} + C_{1,0})} \sim \chi_1^2 \quad (5.8)$$

onde C é a matriz de contingência.

O valor do P -value para o teste de McNemar pode ser aproximado da seguinte maneira:

$$P\text{-value} \sim f(x, k) = \frac{1}{2^{k/2} \Gamma(k/2)} x^{k/2-1} e^{-x/2} \quad (5.9)$$

onde $x > 0$ é a estatística do teste de McNemar dada na Equação (5.8) e k são os graus de liberdade. Neste caso, para o teste de McNemar $k = 1$.

Assim, novamente, é possível negar a hipótese H_0 quando o P -value for menor do que α .

Outra maneira de avaliar os modelos é a através da análise de quadrante. Nesta análise é verificado se os modelos concordam ou discordam a partir do ponto de vista das distribuições das variáveis de calorimetria utilizadas na identificação *offline* de elétrons.

Com esta análise é possível avaliar quatro possibilidades mutuamente exclusivas para dois modelos (A e B): ambos os modelos aceitam o candidato (caso 1); ambos os modelos rejeitam o candidato (caso 2); apenas o modelo A aceita o candidato (caso 3); apenas o modelo B aceita o candidato (caso 4).

A última forma de avaliar os modelos é a partir da emulação das cadeias de Trigger. Para isto foi emulado um conjunto de cadeias de filtragem, conforme disposto

na Tabela 5.4.

Para cada uma das cadeias da Tabela 5.4 o classificador da etapa `FastCalo` foi substituído pelos modelos avaliados e o $V8_F$. Assim, para uma mesma cadeia foram obtidas cinco variações que operam com diferentes estratégias de seleção no `FastCalo`. O P_D e o P_F , para cada uma das etapas de uma dada cadeia de filtragem (*chain*), pode ser definido como:

$$\begin{aligned}
 P_{Dchain} &= P(\text{candidato} = \text{elétron} | \text{condição do } \textit{offline}) = \frac{N_{\text{aprovados na chain}}}{N_{\text{offline}}} \\
 P_{Fchain} &= P(\text{candidato} = \text{elétron} | \text{rejeitado pelo } \textit{offline}) = \frac{N_{\text{aprovados na chain}}}{N_{\text{rejeitados}}}
 \end{aligned}
 \tag{5.10}$$

Tabela 5.4: Cadeias de filtragem utilizadas no processo de emulação local.

Cadeias Emuladas
HLT_e17_lhtight_nod0_L1_EM15VHI
HLT_e17_lhmedium_nod0_L1_EM15VHI
HLT_e17_lhloose_nod0_L1_EM15VHI
HLT_e17_lhvloose_nod0_L1_EM15VHI

As cadeias de filtragem do `ATLAS` aplicam diferentes critérios para seleção durante a coleta de dados, tais configurações estão expostas de forma explícita no nome das cadeias (*chains*). A nomenclatura das cadeias indica qual o patamar mínimo de energia, a assinatura em questão (os elétrons, por exemplo, tem um prefixo *e*), os critérios de qualidade, algumas informações extras para seleção do `HLT` e em letras maiúsculas estão dispostos os critérios para o `L1Calo`. Assim, para as cadeias dispostas na Tabela 5.4 são exigidos elétrons com no mínimo de 17 GeV de E_T e selecionados por critérios *Tight*, *Medium*, *Loose* ou *Very Loose*. A informação extra presente nas cadeias, *nod0*, indica que a estratégia de seleção via *Likelihood* não utiliza a variável d_0 . Por fim, os objetos do `L1Calo` selecionados para estas cadeias precisam ter pelo menos $E_T > 15$ GeV e as letras V, H e I indicam respectivamente que os limiares de corte variam em função de η , do isolamento do núcleo hadrônico e do isolamento eletromagnético.

Capítulo 6

Resultados

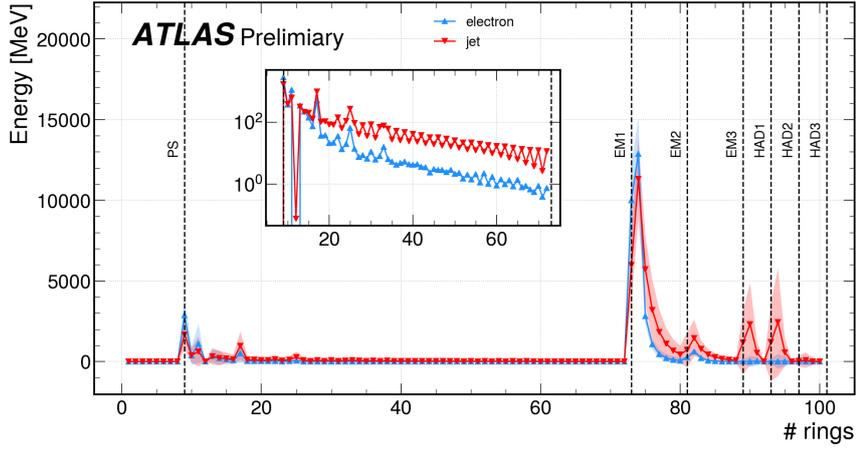
Neste capítulo serão expostos os resultados obtidos com base no método proposto no Capítulo 5. A quantidade de amostras disponíveis para realizar os treinamentos dos modelos que compõem o *ensemble* e também sua avaliação, além do ajuste em função $\langle \mu \rangle$ para manter a eficiência aproximadamente constante em função do empilhamento. Os testes de hipóteses realizados para avaliar semelhanças entre o modelo $V8_F$ e os modelos treinados sobre a redução sintética da granularidade, bem como a análise do ponto de vista do quadrante serão exploradas. Por fim, os resultados de emulação das *chains* mencionadas na Tabela 5.4 são exibidos.

A seleção empregada nos dados de colisão de 2017 que foram utilizados para o treinamento e nos de 2018 utilizados para validação estão descritos na Seção 5.1 e na Tabela 6.1. Os dados obtidos foram submetidos a redução sintética de granularidade com objetivo de simular condições mais próximas da região com $|\eta| > 2,5$. Na Figura 6.1a é apresentado o perfil médio dos anéis antes da redução sintética de granularidade e na Figura 6.1b está disposto o perfil médio das amostras após a remoção dos anéis do PS e EM3.

Tabela 6.1: Amostras de colisão obtidas dos dados de 2017 e 2018. A amostra de sinal é composta por candidatos aprovados pelo critério *Medium* do *offline* e a quantidade está azul na tabela. Já as amostras de evento de jatos é composta por candidatos reprovados pelo critério *Very Loose* do *offline* e as quantidades estão dispostas em vermelho

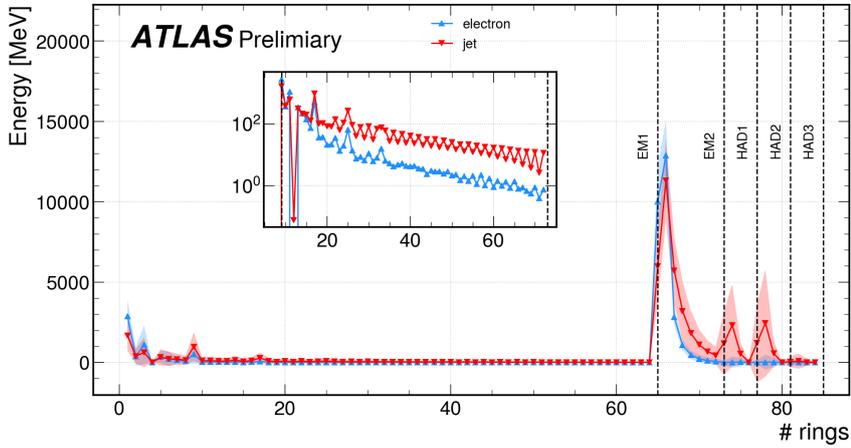
# Quantidade de amostras	Período de colisão	$15 \leq E_T [\text{Gev}] < 20$	$20 \leq E_T [\text{Gev}] < 30$	$30 \leq E_T [\text{Gev}] < 45$	$40 \leq E_T [\text{Gev}] < 50$	$E_T [\text{Gev}] \geq 50$
2, $37 \leq \eta < 2,47$	2017	19765	83992	164364	187727	89782
		15512	36522	24980	16100	93785
	2018	20412	85546	164810	185350	87427
		13184	27966	19260	12077	74847

Collision Data 2017 Mean Rings Profile | $E_T \in [30, 40[$ GeV $\eta \in [2.37, 2.47[$



(a)

Collision Data 2017 Mean Rings Profile Forward Emulation | $E_T \in [30, 40[$ GeV $\eta \in [2.37, 2.47[$



(b)

Figura 6.1: Perfil médio dos anéis em dados de colisão de 2017 para região de $20 \leq E_T < 30$ GeV e $2,37 \leq |\eta| < 2,47$ do *ensemble*. 6.1a mostra o perfil com os 100 anéis, onde em azul está representado o sinal e em vermelho está representado o ruído de fundo. 6.1b mostra o perfil já com a redução sintética da granularidade, totalizando 84 anéis. As áreas sombreadas em azul e vermelho indicam os valores da raiz quadrada da variância para o sinal e para os jatos, respectivamente.

6.1 Resultados da Validação Cruzada e Seleção dos Modelos

O treinamento dos modelos aplicou o *K-Fold* estratificado com $K = 10$ como método de validação cruzada para realizar a estimação da incerteza estatística dos modelos. Para auxiliar a escolha da topologia para os modelos MLP foram criados *boxplots* em função do SP_{\max} , conforme pode ser visto na Figura 6.2 para cada região do *ensemble* com o conjunto de teste de cada *fold* para a melhor inicialização. Conforme pode-se observar na Figura 6.2 o modelo MLP com 2 neurônios na camada

escondida possui performance similar aos outros modelos [MLP](#) e pelo critério de parcimônia optou-se por utilizar este modelo com 2 neurônios para realizar as demais análises.

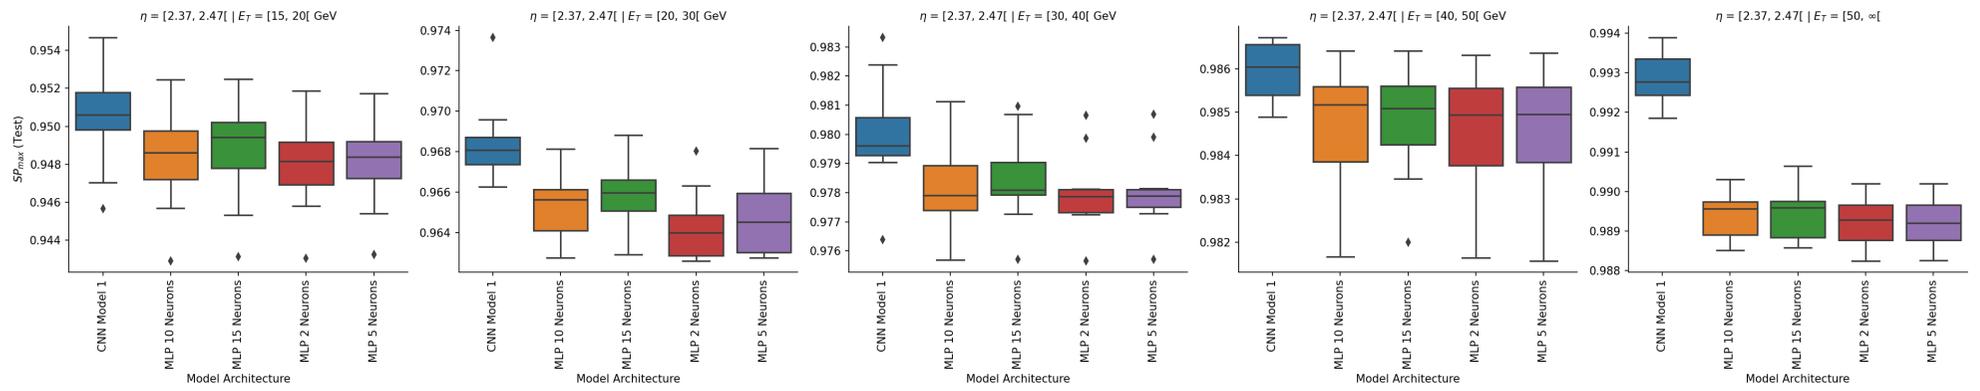


Figura 6.2: *Boxplot* do SP_{max} para cada região do *ensemble*.

Selecionada a topologia do modelo *MLP*, são realizados ajustes para que estes operem segundo os critérios do *ATLAS*. O ajuste é realizado a partir do P_D do *CutBased* em cada uma das regiões do *ensemble* e com isso é possível avaliar a incerteza dos modelos em relação ao P_F . Na Tabela 6.2 estão dispostos os valores da média e da incerteza em cada região do *ensemble* para cada ponto de operação. Em verde está a coluna do P_D indicando que todos os modelos devem operar seguindo a referência do *CutBased*. Ao analisar os P_F obtidos pelos modelos *CNN* e *MLP2* nota-se que ambos possuem performance similar, embora o modelo *CNN* apresente uma incerteza associada a medida menor. Cabe destacar que houve grande redução do P_F para ambos os modelos em comparação ao *CutBased*, em alguns casos a redução foi maior do que 50%. Com relação aos dados de 2018 também foi observado redução no valor do P_F e pequenas flutuações no P_D .

Operation Det. Region		Tight $2,37 \leq \eta < 2,47$			Medium $2,37 \leq \eta < 2,47$			Loose $2,37 \leq \eta < 2,47$			Very Loose $2,37 \leq \eta < 2,47$			
kinematic region	Method	Type	$P_D\%$	$SP\%$	$P_F\%$	$P_D\%$	$SP\%$	$P_F\%$	$P_D\%$	$SP\%$	$P_F\%$	$P_D\%$	$SP\%$	$P_F\%$
$15 \leq E_T[\text{Gev}] < 20$	MLP2 CNN	Cut-Based (2017)	93,51	71,19	48,06	93,54	70,45	49,34	93,92	61,82	63,46	93,95	59,24	67,31
		Ringer (2017)	$93,51 \pm 0,15$	$94,26 \pm 0,21$	$4,99 \pm 0,38$	$93,53 \pm 0,15$	$94,26 \pm 0,21$	$5,01 \pm 0,35$	$93,97 \pm 0,14$	$94,40 \pm 0,20$	$5,18 \pm 0,35$	$94,02 \pm 0,11$	$94,41 \pm 0,21$	$5,19 \pm 0,34$
		Ringer (2017)	$93,51 \pm 0,10$	$94,39 \pm 0,22$	$4,73 \pm 0,42$	$93,57 \pm 0,09$	$94,41 \pm 0,21$	$4,74 \pm 0,43$	$93,90 \pm 0,08$	$94,50 \pm 0,22$	$4,90 \pm 0,39$	$93,91 \pm 0,08$	$94,50 \pm 0,22$	$4,91 \pm 0,40$
	MLP2 CNN	Cut-Based (2018)	93,92	70,49	49,55	93,94	69,60	51,05	94,34	61,25	64,57	94,35	58,68	68,34
		Ringer (2018)	93,60	93,61	6,39	93,62	93,61	6,39	93,95	93,68	6,58	93,98	93,69	6,60
		Ringer (2018)	93,61	93,72	6,17	93,62	93,72	6,18	93,90	93,80	6,30	93,90	93,79	6,31
$20 \leq E_T[\text{Gev}] < 30$	MLP2 CNN	Cut-Based (2017)	95,74	74,48	44,10	95,74	74,23	44,52	95,75	71,90	48,50	95,79	69,32	52,82
		Ringer (2017)	$95,75 \pm 0,04$	$95,92 \pm 0,18$	$3,92 \pm 0,35$	$95,76 \pm 0,03$	$95,91 \pm 0,18$	$3,93 \pm 0,35$	$95,76 \pm 0,03$	$95,91 \pm 0,18$	$3,93 \pm 0,35$	$95,79 \pm 0,03$	$95,92 \pm 0,17$	$3,95 \pm 0,35$
		Ringer (2017)	$95,76 \pm 0,03$	$96,18 \pm 0,17$	$3,40 \pm 0,34$	$95,76 \pm 0,03$	$96,18 \pm 0,17$	$3,40 \pm 0,34$	$95,76 \pm 0,03$	$96,18 \pm 0,17$	$3,40 \pm 0,34$	$95,78 \pm 0,03$	$96,18 \pm 0,17$	$3,42 \pm 0,34$
	MLP2 CNN	Cut-Based (2018)	95,73	74,63	43,82	95,73	74,40	44,22	95,74	72,06	48,23	95,79	69,47	52,58
		Ringer (2018)	95,83	95,73	4,37	95,83	95,73	4,37	95,83	95,73	4,37	95,87	95,74	4,39
		Ringer (2018)	95,75	95,94	3,87	95,75	95,94	3,87	95,75	95,94	3,87	95,80	95,96	3,89
$30 \leq E_T[\text{Gev}] < 40$	MLP2 CNN	Cut-Based (2017)	96,70	77,12	48,06	96,70	77,02	40,42	96,70	76,43	41,45	96,72	73,78	46,03
		Ringer (2017)	$96,69 \pm 0,12$	$97,13 \pm 0,17$	$2,44 \pm 0,31$	$96,69 \pm 0,12$	$97,13 \pm 0,17$	$2,44 \pm 0,31$	$96,69 \pm 0,12$	$97,13 \pm 0,17$	$2,44 \pm 0,31$	$96,73 \pm 0,12$	$97,14 \pm 0,15$	$2,44 \pm 0,31$
		Ringer (2017)	$96,81 \pm 0,12$	$97,26 \pm 0,14$	$2,29 \pm 0,29$	$96,81 \pm 0,12$	$97,26 \pm 0,14$	$2,29 \pm 0,29$	$96,81 \pm 0,12$	$97,26 \pm 0,14$	$2,29 \pm 0,29$	$96,81 \pm 0,12$	$97,26 \pm 0,14$	$2,29 \pm 0,29$
	MLP2 CNN	Cut-Based (2018)	96,61	77,21	40,01	96,61	77,10	40,20	96,61	76,51	41,24	96,62	73,63	46,21
		Ringer (2018)	96,82	96,96	2,90	96,82	96,96	2,90	96,82	96,96	2,90	96,82	96,96	2,90
		Ringer (2018)	96,82	97,04	2,75	96,82	97,04	2,75	96,82	97,04	2,75	96,82	97,04	2,75
$40 \leq E_T[\text{Gev}] < 50$	MLP2 CNN	Cut-Based (2017)	97,13	77,32	40,22	97,13	77,23	40,38	97,13	76,63	41,43	97,13	73,80	46,31
		Ringer (2017)	$97,28 \pm 0,27$	$97,84 \pm 0,23$	$1,61 \pm 0,22$	$97,28 \pm 0,27$	$97,84 \pm 0,23$	$1,61 \pm 0,22$	$97,28 \pm 0,27$	$97,84 \pm 0,23$	$1,61 \pm 0,22$	$97,28 \pm 0,27$	$97,84 \pm 0,23$	$1,61 \pm 0,22$
		Ringer (2017)	$97,15 \pm 0,16$	$97,82 \pm 0,11$	$1,50 \pm 0,19$	$97,15 \pm 0,16$	$97,82 \pm 0,11$	$1,50 \pm 0,19$	$97,15 \pm 0,16$	$97,82 \pm 0,11$	$1,50 \pm 0,19$	$97,15 \pm 0,16$	$97,82 \pm 0,11$	$1,50 \pm 0,19$
	MLP2 CNN	Cut-Based (2018)	97,11	77,22	40,38	97,11	77,14	40,52	97,11	76,68	41,33	97,11	73,82	46,25
		Ringer (2018)	97,32	97,56	2,20	97,32	97,56	2,20	97,32	97,56	2,20	97,32	97,56	2,20
		Ringer (2018)	97,25	97,61	2,03	97,25	97,61	2,03	97,25	97,61	2,03	97,25	97,61	2,03
$E_T[\text{Gev}] > 50$	MLP2 CNN	Cut-Based (2017)	96,02	52,49	77,49	96,02	52,39	77,61	96,02	51,79	78,35	96,02	50,46	79,95
		Ringer (2017)	$95,99 \pm 0,13$	$97,57 \pm 0,10$	$0,83 \pm 0,11$	$95,99 \pm 0,13$	$97,57 \pm 0,10$	$0,83 \pm 0,11$	$95,99 \pm 0,13$	$97,57 \pm 0,10$	$0,83 \pm 0,11$	$95,99 \pm 0,13$	$97,57 \pm 0,10$	$0,83 \pm 0,11$
		Ringer (2017)	$96,00 \pm 0,05$	$97,76 \pm 0,04$	$0,46 \pm 0,07$	$96,00 \pm 0,05$	$97,76 \pm 0,04$	$0,46 \pm 0,07$	$96,00 \pm 0,05$	$97,76 \pm 0,04$	$0,46 \pm 0,07$	$96,00 \pm 0,05$	$97,76 \pm 0,04$	$0,46 \pm 0,07$
	MLP2 CNN	Cut-Based (2018)	96,01	52,50	77,47	96,01	52,39	77,61	96,01	51,82	78,31	96,01	50,54	79,85
		Ringer (2018)	96,11	97,57	0,954	96,11	97,57	0,95	96,11	97,57	0,95	96,11	97,57	0,95
		Ringer (2018)	96,14	97,79	0,54	96,14	97,79	0,54	96,14	97,79	0,54	96,14	97,79	0,54

Tabela 6.2: Valores P_D , P_F e SP para cada região do *ensemble* para e para todos os critérios de operação do **Trigger** antes do ajuste em função de $\langle \mu \rangle$ seguindo a referência do *Cut-Based* as incertezas são estimadas do conjunto dos *folds* de treinamento (dados de 2017) e na validação *out-of-sample* (2018).

As Figuras 6.3 e 6.4 mostram, respectivamente, a evolução do treinamento do modelo MLP2 e do modelo CNN para a região $20 \leq E_T \text{ GeV} < 30$ para um dado *fold*. Nestas figuras é possível avaliar o MSE, o P_D , o SP e o P_F ao longo das épocas, bem como a *Receiver Operation Curve* (ROC) obtida no conjunto de teste com marcações para os pontos de operação, além do histograma do neurônio de saída dos modelos com os patamares representados por linhas verticais. Conforme o esperado, na medida em que o SP aumenta, os níveis de P_D e P_F estabilizam-se durante o treinamento.

Train Fold: 4 -> $E_T \in [30, 40[$ GeV | $\eta \in [2.37, 2.47[$

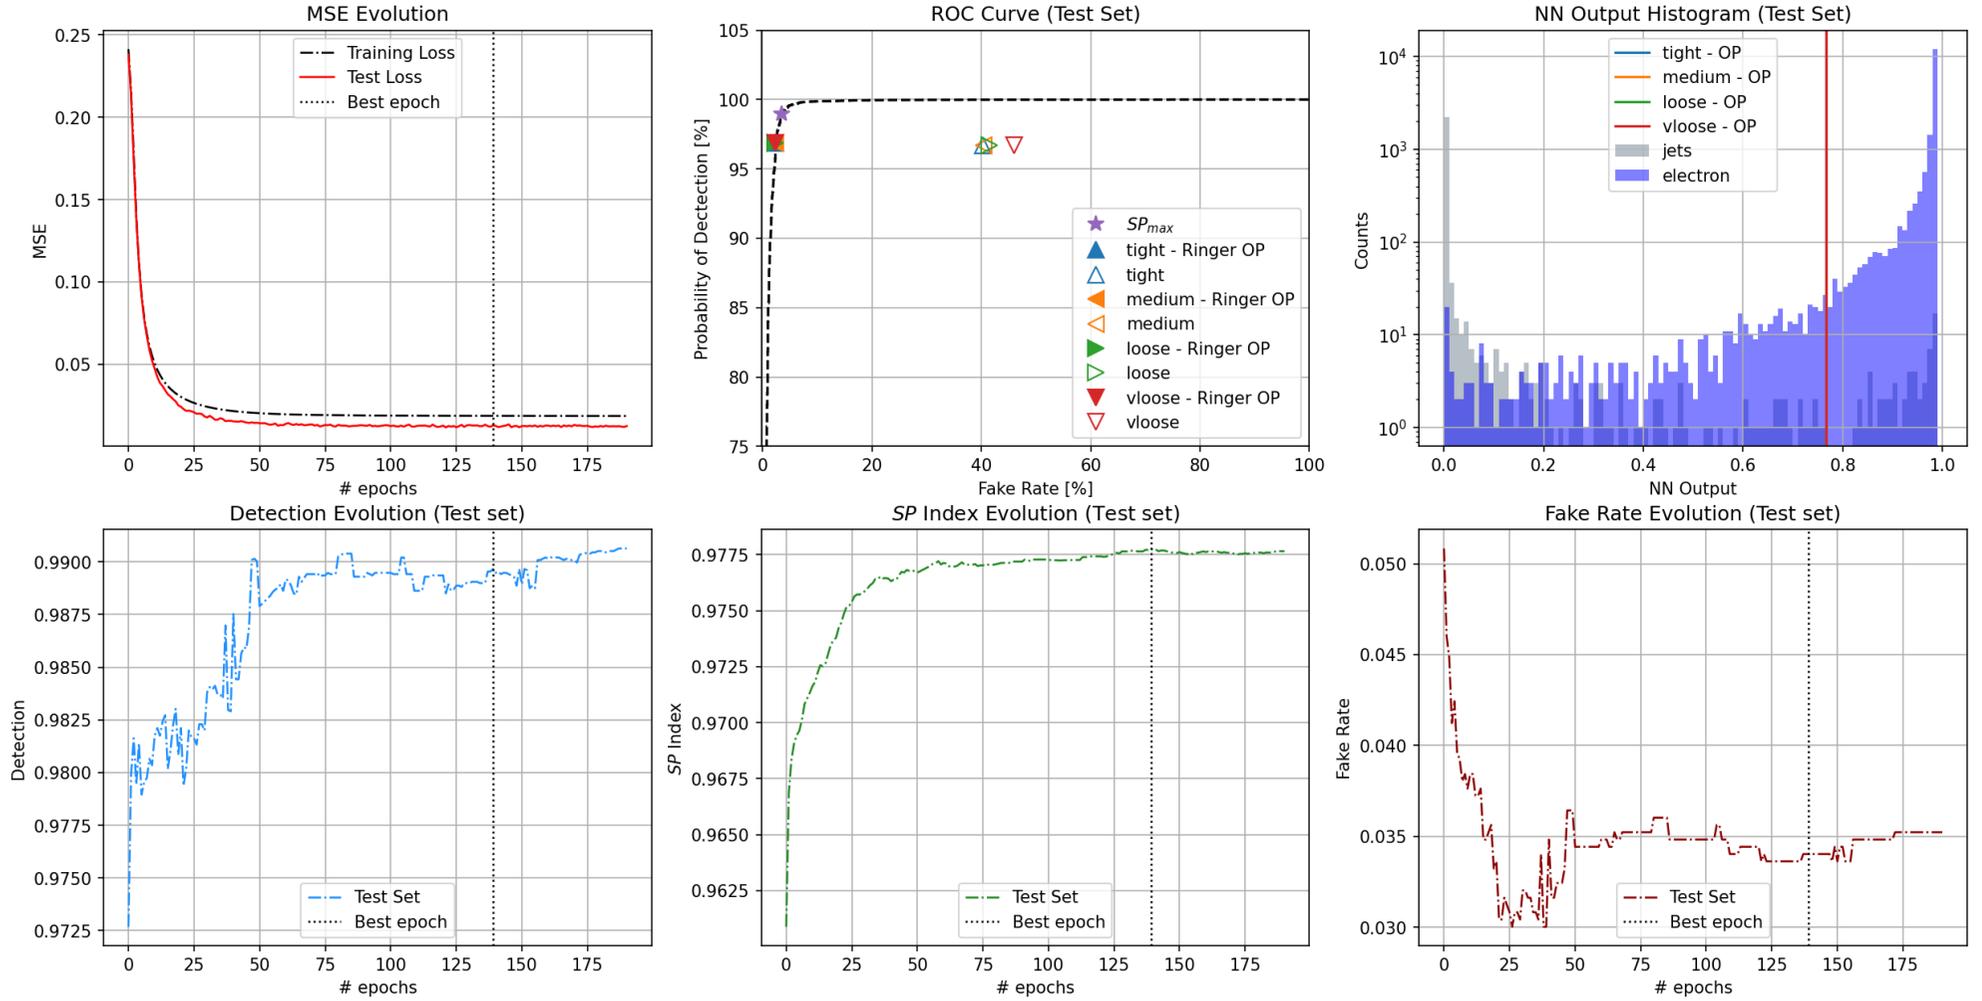


Figura 6.3: Evolução do treinamento do modelo MLP2 em um *fold* para cada região de $20 \leq E_T < 30$ GeV. Os gráficos da parte superior são, respectivamente, o MSE ao longo das épocas, a ROC e o histograma do neurônios da camada de saída. Na parte inferior estão a evolução do P_D , do SP e do P_F ao longo das épocas do treinamento.

Train Fold: 4 -> $E_T \in [30, 40[$ GeV | $\eta \in [2.37, 2.47[$

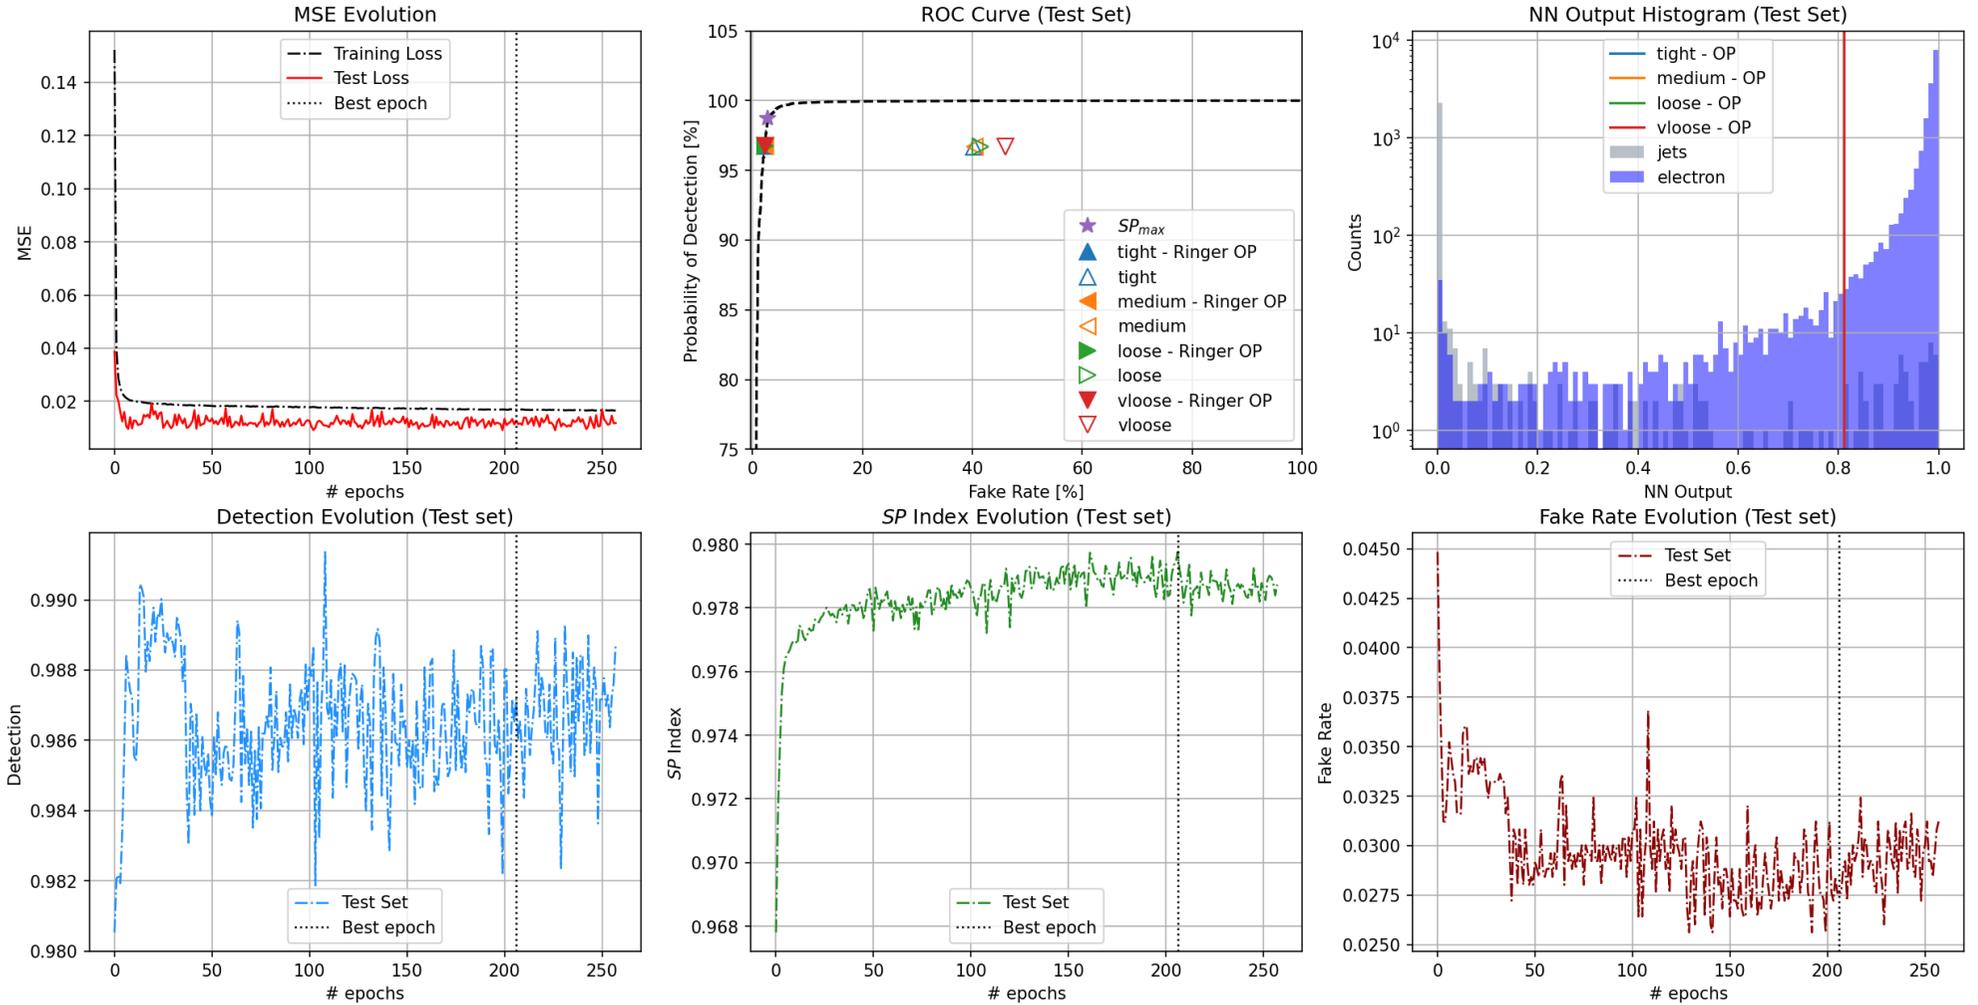


Figura 6.4: Evolução do treinamento do modelo CNN em um *fold* para cada região de $20 \leq E_T < 30$ GeV. Os gráficos da parte superior são, respectivamente, o MSE ao longo das épocas, a ROC e o histograma do neurônios da camada de saída. Na parte inferior estão a evolução do P_D , do SP e do P_F ao longo das épocas do treinamento.

6.2 Ajuste de Eficiência em Função de $\langle\mu\rangle$

O Capítulo 5 menciona a necessidade de corrigir os modelos para que não haja perda na eficiência conforme o empilhamento aumenta durante as colisões. A adoção da estratégia baseada em um ajuste linear na saída do classificador torna os modelos resistentes a este efeito.

Na Figura 6.5 temos um exemplo da correção em função de $\langle\mu\rangle$ para região $20 \leq E_T < 30$ GeV para os modelos MLP2 e CNN

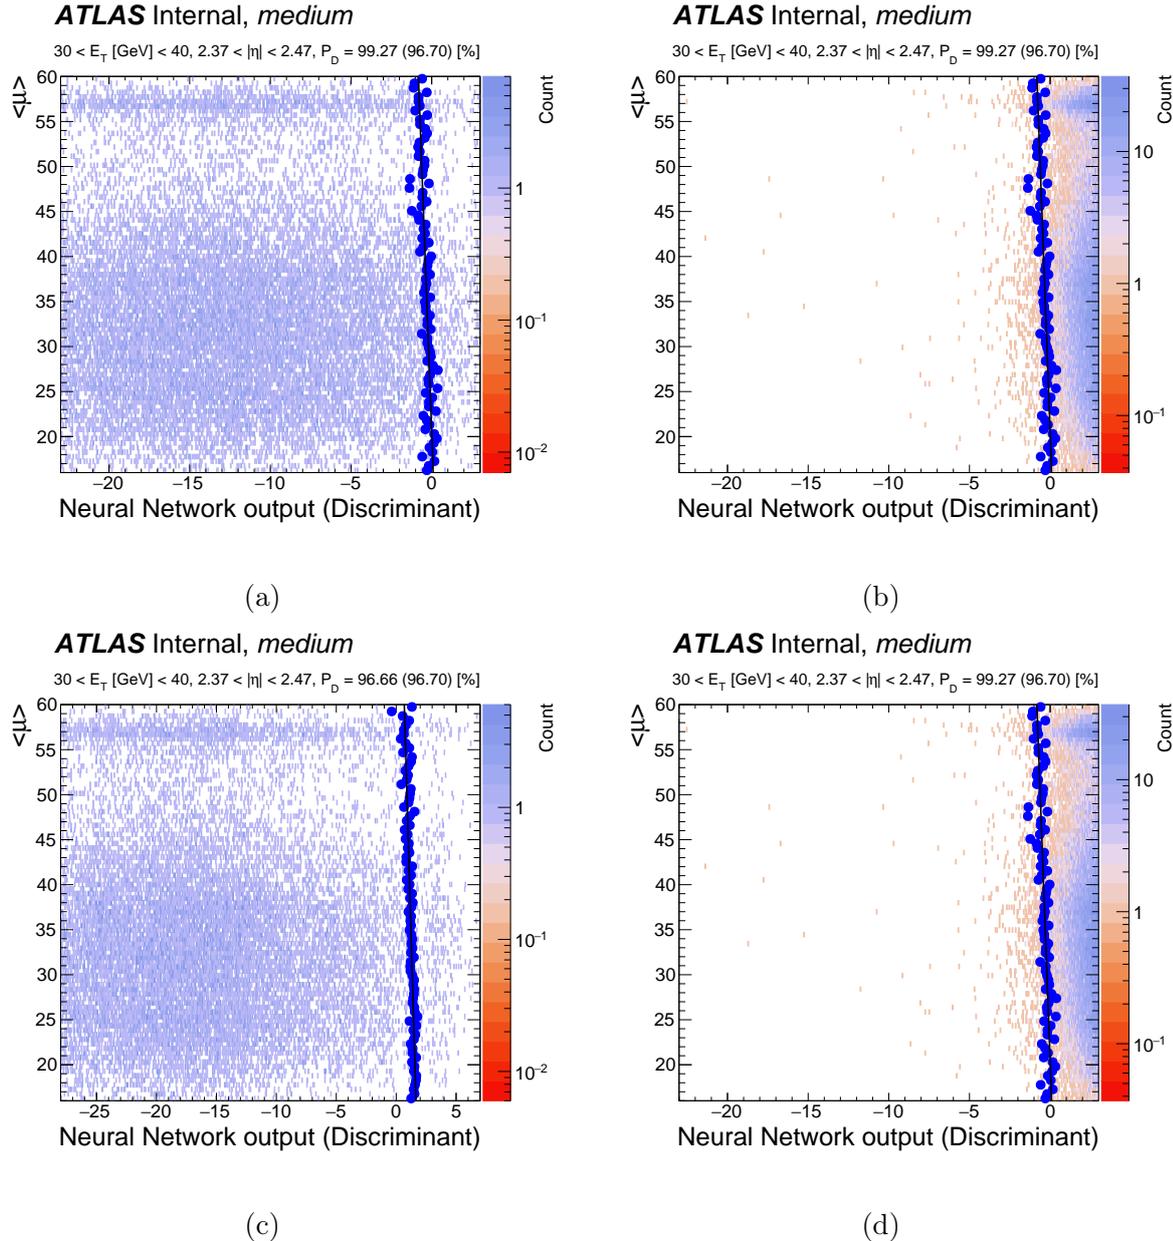


Figura 6.5: Saída dos modelos em função de $\langle\mu\rangle$. Nas Figuras (a) e (b) temos saída do modelo MLP2 onde na esquerda está o background e à direita estão as amostras de sinal. Já nas Figura (c) e (d) temos saída do modelo CNN onde à esquerda está o background e à direita estão as amostras de sinal.

Mediante a obtenção dos ajustes em função de $\langle \mu \rangle$, os valores da Tabela 6.4 são recalculados, desta vez utilizando o ajuste linear obtido. Os resultados para cada uma das regiões do *ensemble* estão expostos na Tabela 6.3 e na Tabela 6.4 estão os valores integrados, ou seja, para todo o *ensemble*. Os resultados mostram um aumento no P_F , o que é esperado devido ao ajuste em função do empilhamento. A remoção da não-linearidade da camada de saída ocasionou um aumento nas incertezas obtidas na validação cruzada, porém ao avaliar os valores integrados nota-se que os modelos MLP2 e CNN obtiveram valores próximos ao da referência.

Operation Det. Region		Tight $2,37 \leq \eta < 2,47$			Medium $2,37 \leq \eta < 2,47$			Loose $2,37 \leq \eta < 2,47$			Very Loose $2,37 \leq \eta < 2,47$			
kinematic region	Method	Type	$P_D\%$	$SP\%$	$P_F\%$	$P_D\%$	$SP\%$	$P_F\%$	$P_D\%$	$SP\%$	$P_F\%$	$P_D\%$	$SP\%$	$P_F\%$
$15 \leq E_T$ [Gev] < 20	V8 $V8_F$ MLP2 CNN	Cut-Based (2017)	93,51	71,19	48,06	93,54	70,45	49,34	93,92	61,82	63,46	93,95	59,24	67,31
		Ringer (2017)	94,26	94,69	4,88	96,57	94,81	6,94	95,97	94,89	6,19	97,54	94,00	9,48
		Ringer (2017)	96,76	94,48	7,77	97,79	93,57	10,55	97,49	93,98	9,46	98,24	92,09	13,87
		Ringer (2017)	94,71 ± 2,78	93,52 ± 1,05	7,60 ± 4,38	94,72 ± 2,77	93,52 ± 1,05	7,61 ± 4,37	95,00 ± 2,64	93,47 ± 1,23	7,98 ± 4,65	95,05 ± 2,61	93,46 ± 1,28	8,06 ± 4,72
		Ringer (2017)	94,11 ± 1,11	94,47 ± 0,19	5,16 ± 1,05	94,13 ± 1,11	94,47 ± 0,19	5,18 ± 1,04	94,50 ± 1,00	94,56 ± 0,17	5,38 ± 1,11	94,54 ± 0,99	94,58 ± 0,17	5,38 ± 1,13
		Cut-Based (2018)	93,92	70,49	49,55	93,94	69,60	51,05	94,34	61,25	64,57	94,35	58,68	68,34
	V8 $V8_F$ MLP2 CNN	Ringer (2018)	94,38	93,95	6,47	96,52	93,77	8,94	95,90	93,91	8,07	97,70	93,01	11,56
		Ringer (2018)	96,81	93,61	9,53	97,91	92,60	12,56	97,59	92,99	11,50	98,46	91,14	15,89
		Ringer (2018)	93,56	93,57	6,42	93,58	93,58	6,42	94,47	93,67	7,12	94,06	93,66	6,74
		Ringer (2018)	95,66	94,01	7,62	95,68	94,02	7,62	96,00	94,00	7,98	96,02	94,01	7,99
		Cut-Based (2017)	95,74	74,48	44,10	95,74	74,23	44,52	95,75	71,90	48,50	95,79	69,32	52,82
		Ringer (2017)	94,84	95,81	3,20	97,41	96,54	4,33	96,76	96,40	3,95	98,32	96,57	5,17
$20 \leq E_T$ [Gev] < 30	V8 $V8_F$ MLP2 CNN	Ringer (2017)	98,65	96,26	6,09	99,29	95,72	7,78	99,13	95,98	7,13	99,50	95,21	8,99
		Ringer (2017)	97,35 ± 1,54	96,09 ± 0,27	5,15 ± 1,32	97,35 ± 1,55	96,09 ± 0,28	5,15 ± 1,32	97,35 ± 1,55	96,09 ± 0,28	5,15 ± 1,32	97,38 ± 1,53	96,09 ± 0,27	5,17 ± 1,33
		Ringer (2017)	95,57 ± 0,39	96,14 ± 0,20	3,28 ± 0,36	95,57 ± 0,38	96,15 ± 0,20	3,28 ± 0,36	95,57 ± 0,38	96,15 ± 0,20	3,28 ± 0,36	95,62 ± 0,38	96,16 ± 0,21	3,30 ± 0,35
		Cut-Based (2018)	95,73	74,63	43,82	95,73	74,40	44,22	95,74	72,06	48,23	95,79	69,47	52,58
		Ringer (2018)	94,94	95,58	3,77	96,28	96,79	4,89	96,79	96,15	4,48	98,36	96,33	5,67
		Ringer (2018)	98,71	96,04	6,60	99,34	95,51	8,23	99,20	95,72	7,70	99,55	95,01	9,42
	V8 $V8_F$ MLP2 CNN	Ringer (2018)	98,39	96,15	6,07	98,39	96,15	6,07	98,39	96,15	6,07	98,40	96,14	6,09
		Ringer (2018)	95,87	96,04	3,79	95,87	96,04	3,79	95,87	96,04	3,79	95,91	96,05	3,80
		Cut-Based (2017)	96,70	77,12	48,06	96,70	77,02	40,42	96,70	76,43	41,45	96,72	73,78	46,03
		Ringer (2017)	95,72	96,80	2,11	97,23	97,41	2,41	97,14	97,37	2,39	98,59	97,82	2,95
		Ringer (2017)	98,93	97,71	3,50	99,32	97,63	4,05	99,30	97,64	4,02	99,64	97,31	4,98
		Ringer (2017)	97,29 ± 1,20	97,20 ± 0,33	2,87 ± 0,71	97,29 ± 1,20	97,20 ± 0,33	2,87 ± 0,71	97,29 ± 1,20	97,20 ± 0,33	2,87 ± 0,71	97,29 ± 1,20	97,20 ± 0,33	2,88 ± 0,70
$30 \leq E_T$ [Gev] < 40	V8 $V8_F$ MLP2 CNN	Ringer (2017)	96,59 ± 0,23	97,17 ± 0,17	2,25 ± 0,34	96,59 ± 0,23	97,17 ± 0,17	2,25 ± 0,34	96,59 ± 0,23	97,17 ± 0,17	2,25 ± 0,34	96,60 ± 0,22	97,17 ± 0,17	2,26 ± 0,35
		Cut-Based (2018)	96,61	77,21	40,01	96,61	77,10	40,20	96,61	76,51	41,24	96,62	73,63	46,21
		Ringer (2018)	95,86	96,69	2,48	97,35	97,23	2,88	97,27	97,20	2,87	98,67	97,56	3,55
		Ringer (2018)	99,02	97,43	4,14	99,38	97,33	4,70	99,37	97,34	4,66	99,66	96,92	5,78
		Ringer (2018)	99,03	97,49	4,04	99,03	97,49	4,04	99,03	97,49	4,04	99,03	97,49	4,04
		Ringer (2018)	96,90	97,09	2,72	96,90	97,09	2,72	96,90	97,09	2,72	96,91	97,10	2,72
	V8 $V8_F$ MLP2 CNN	Cut-Based (2017)	97,13	77,32	40,22	97,13	77,23	40,38	97,13	76,63	41,43	97,13	73,80	46,31
		Ringer (2017)	95,98	97,34	1,29	96,34	97,50	1,32	97,72	98,06	1,60	97,86	98,12	1,62
		Ringer (2017)	99,36	98,34	2,68	99,43	98,33	2,76	99,66	98,26	3,12	99,68	98,25	3,16
		Ringer (2017)	98,36 ± 1,27	98,11 ± 0,44	2,14 ± 0,44	98,36 ± 1,27	98,11 ± 0,44	2,14 ± 0,44	98,36 ± 1,27	98,11 ± 0,44	2,14 ± 0,44	98,36 ± 1,27	98,11 ± 0,44	2,14 ± 0,44
		Ringer (2017)	97,08 ± 0,29	97,80 ± 0,17	1,47 ± 0,14	97,08 ± 0,29	97,80 ± 0,17	1,47 ± 0,14	97,08 ± 0,29	97,80 ± 0,17	1,47 ± 0,14	97,08 ± 0,29	97,81 ± 0,17	1,47 ± 0,14
		Cut-Based (2018)	97,11	77,22	40,38	97,11	77,14	40,52	97,11	76,68	41,33	97,11	73,82	46,25
$40 \leq E_T$ [Gev] < 50	V8 $V8_F$ MLP2 CNN	Ringer (2018)	96,09	97,12	1,84	96,46	97,30	1,86	97,79	97,81	2,17	97,91	97,87	2,18
		Ringer (2018)	99,40	98,11	3,16	99,46	98,11	3,23	99,68	98,00	3,66	99,70	98,00	3,69
		Ringer (2018)	99,42	98,17	3,06	99,42	98,17	3,06	99,42	98,17	3,06	99,42	98,17	3,06
		Ringer (2018)	97,09	97,61	1,87	97,09	97,61	1,87	97,09	97,61	1,87	97,09	97,61	1,87
		Cut-Based (2017)	96,02	52,49	77,49	96,02	52,39	77,61	96,02	51,79	78,35	96,02	50,46	79,95
		Ringer (2017)	97,48	98,27	0,93	98,80	98,78	1,24	99,13	98,88	1,36	99,47	98,92	1,63
	V8 $V8_F$ MLP2 CNN	Ringer (2017)	99,62	98,80	2,02	99,80	98,64	2,52	99,85	98,54	2,77	99,89	98,33	3,21
		Ringer (2017)	97,11 ± 1,57	98,05 ± 0,69	1,01 ± 0,22	97,11 ± 1,57	98,05 ± 0,69	1,01 ± 0,22	97,11 ± 1,57	98,05 ± 0,69	1,01 ± 0,22	97,11 ± 1,57	98,05 ± 0,69	1,01 ± 0,22
		Ringer (2017)	95,95 ± 0,24	97,73 ± 0,14	0,46 ± 0,08	95,95 ± 0,24	97,73 ± 0,14	0,46 ± 0,08	95,95 ± 0,24	97,73 ± 0,14	0,46 ± 0,08	95,95 ± 0,24	97,73 ± 0,14	0,46 ± 0,08
		Cut-Based (2018)	96,01	52,50	77,47	96,01	52,39	77,61	96,01	51,82	78,31	96,01	50,54	79,85
		Ringer (2018)	97,55	98,26	1,02	98,84	98,76	1,32	99,16	98,86	1,43	99,48	98,91	1,65
		Ringer (2018)	99,63	98,81	2,02	99,80	98,65	2,49	99,85	98,55	2,75	99,89	98,38	3,11
V8 $V8_F$ MLP2 CNN	Ringer (2018)	99,01	98,81	1,40	99,01	98,81	1,40	99,01	98,81	1,40	99,01	98,81	1,40	
	Ringer (2018)	96,14	97,79	0,54	96,14	97,79	0,54	96,14	97,79	0,54	96,14	97,79	0,54	

Tabela 6.3: Valores P_D , P_F e SP para cada região do *ensemble* para e para todos os critérios de operação do **Trigger** após do ajuste em função de $\langle \mu \rangle$ seguindo a referência do *Cut-Based* as incertezas são estimadas do conjunto dos *folds* de treinamento (dados de 2017) e na validação *out-of-sample* (2018). Também estão dispostas na tabela os valores de eficiência obtidos para o modelo $V8$ e $V8_F$.

Tabela 6.4: Resultados integrados obtidos pelo *NeuralRinger* após o ajuste dos modelos em função de $\langle \mu \rangle$ para todos os pontos de operação do ATLAS. As incertezas são obtidas dos *folders*.

Critério	Tipo	P_D	P_F
Tight	<i>Cut-Based</i> (2017)	96,48	60,33
	<i>Ringer V8</i> (2017)	95,91	1,89
	<i>Ringer V8_F</i> (2017)	99,07	3,55
	<i>MLP 2 neurônios</i> (2017)	97,54 ± 0,56	2,71 ± 0,47
	<i>CNN</i> (2017)	96,40 ± 0,16	1,73 ± 0,11
	<i>Cut-Based</i> (2018)	96,45	60,65
	<i>Ringer V8</i> (2018)	96,01	2,29
	<i>Ringer V8_F</i> (2018)	99,12	3,93
	<i>MLP 2 neurônios</i> (2018)	98,85	3,22
	<i>CNN</i> (2018)	96,63	2,18
Medium	<i>Cut-Based</i> (2017)	96,48	60,62
	<i>Ringer V8</i> (2017)	97,19	2,48
	<i>Ringer V8_F</i> (2017)	99,38	4,44
	<i>MLP 2 neurônios</i> (2017)	97,55 ± 0,56	2,71 ± 0,47
	<i>CNN</i> (2017)	96,41 ± 0,16	1,73 ± 0,11
	<i>Cut-Based</i> (2018)	96,45	60,96
	<i>Ringer V8</i> (2018)	97,27	2,93
	<i>Ringer V8_F</i> (2018)	99,41	4,83
	<i>MLP 2 neurônios</i> (2018)	98,85	3,22
	<i>CNN</i> (2018)	96,63	2,18
Loose	<i>Cut-Based</i> (2017)	96,49	63,17
	<i>Ringer V8</i> (2017)	97,57	2,43
	<i>Ringer V8_F</i> (2017)	99,42	4,37
	<i>MLP 2 neurônios</i> (2017)	97,56 ± 0,55	2,74 ± 0,48
	<i>CNN</i> (2017)	96,42 ± 0,16	1,75 ± 0,11
	<i>Cut-Based</i> (2018)	96,46	63,49
	<i>Ringer V8</i> (2018)	97,62	2,85
	<i>Ringer V8_F</i> (2018)	99,46	4,80
	<i>MLP 2 neurônios</i> (2018)	98,89	3,28
	<i>CNN</i> (2018)	96,65	2,22
Very Loose	<i>Cut-Based</i> (2017)	96,50	66,17
	<i>Ringer V8</i> (2017)	98,40	3,15
	<i>Ringer V8_F</i> (2017)	99,62	5,45
	<i>MLP 2 neurônios</i> (2017)	97,56 ± 0,55	2,76 ± 0,49
	<i>CNN</i> (2017)	96,43 ± 0,16	1,75 ± 0,11
	<i>Cut-Based</i> (2018)	96,48	66,49
	<i>Ringer V8</i> (2018)	98,46	3,59
	<i>Ringer V8_F</i> (2018)	99,65	5,85
	<i>MLP 2 neurônios</i> (2018)	98,87	3,25
	<i>CNN</i> (2018)	96,66	2,22

6.3 Testes de Hipóteses

Os modelos [MLP2](#) e [CNN](#) foram submetidos a dois testes de hipóteses conforme mencionado no Capítulo 5 utilizando os dados de colisão de 2018. Para comparar a saída do $V8_F$ com a dos modelos foi realizado o teste de Wilcoxon com aproximação Normal para o cálculo do P -value e foi adotado um nível de significância $\alpha = 0,01$ para rejeição da hipótese H_0 . Este teste foi realizado para cada uma das regiões do *ensemble* e os respectivos P -values encontrados estão dispostos na Tabela 6.5. Nota-se que há evidências suficientes para negar H_0 em todas as regiões do *ensemble*, assim podemos concluir que as saídas dos modelos não são iguais à produzida pelo $V8_F$.

Tabela 6.5: Resultados para o teste de Wilcoxon para a comparação da saída do modelo $V8_F$ em relação aos modelos [MLP](#) com 2 neurônios e [CNN](#).

$\alpha = 0,010$	$15 \leq E_T$ [Gev] < 20		$20 \leq E_T$ [Gev] < 30		$30 \leq E_T$ [Gev] < 40		$40 \leq E_T$ [Gev] < 50		$50 \geq E_T$ [Gev]	
	P -value	Rejeita H_0	P -value	Rejeita H_0						
Ringer $V8_F$ Ringer MLP2	0	Sim	0	Sim	0	Sim	0	Sim	0	Sim
Ringer $V8_F$ Ringer CNN	0	Sim	0	Sim	0	Sim	0	Sim	0	Sim

Outro teste estatístico aplicado foi o teste de McNemar. Este teste permitiu avaliar se existe diferença entre os classificadores [MLP2](#) e [CNN](#) em relação ao $V8_F$ para cada região do *ensemble* e para cada um dos pontos de operação. Na Tabela 6.6 estão os resultados do valor do P -value calculado a partir da aproximação de uma distribuição χ^2 considerando $\alpha = 0,01$. Nota-se que para a dos casos a hipótese H_0 pode ser rejeitada, indicando que existem diferenças em relação a performance dos classificadores.

Tabela 6.6: Resultados para o teste de McNemar para a comparação modelo $V8_F$ em relação aos modelos [MLP](#) com 2 neurônios e [CNN](#) com o modelo $V8_F$ em cada um dos pontos de operação.

$\alpha = 0,010$	Operação	$15 \leq E_T$ [Gev] < 20		$20 \leq E_T$ [Gev] < 30		$30 \leq E_T$ [Gev] < 40		$40 \leq E_T$ [Gev] < 50		$50 \geq E_T$ [Gev]	
		P -value	Rejeita H_0	P -value	Rejeita H_0						
Ringer $V8_F$ Ringer MLP2	<i>Tight</i>	0	Sim	0	Sim	0,144	Não	0,042	Sim	0,016	Não
	<i>Medium</i>	0,072	Não	0	Sim	0	Sim	0,008	Sim	0,001	Sim
	<i>Loose</i>	0,099	Não	0	Sim	0	Sim	0	Sim	0	Sim
	<i>Very Loose</i>	0	Sim	0,263	Não	0	Sim	0	Sim	0	Sim
	<i>Very Tight</i>	0,474	Não	0	Sim	0	Sim	0	Sim	0	Sim
Ringer $V8_F$ Ringer CNN	<i>Medium</i>	0	Sim	0	Sim	0	Sim	0	Sim	0	Sim
	<i>Loose</i>	0	Sim	0	Sim	0	Sim	0	Sim	0	Sim
	<i>Very Loose</i>	0	Sim	0	Sim	0	Sim	0	Sim	0	Sim
	<i>Very Tight</i>	0	Sim	0	Sim	0	Sim	0	Sim	0	Sim

Tais resultados são demonstrados na Figura 6.6 onde é possível ver a comparação da saída dos modelos. No gráfico à esquerda temos a comparação da distribuição da saída dos modelos [MLP2](#) e [CNN](#) com o $V8_F$ para a região $15 \leq E_T < 20$ GeV, além das matrizes de contingência utilizadas no teste de McNemar. Os gráficos obtidos para as outras regiões do *ensemble* encontram-se no Apêndice A.

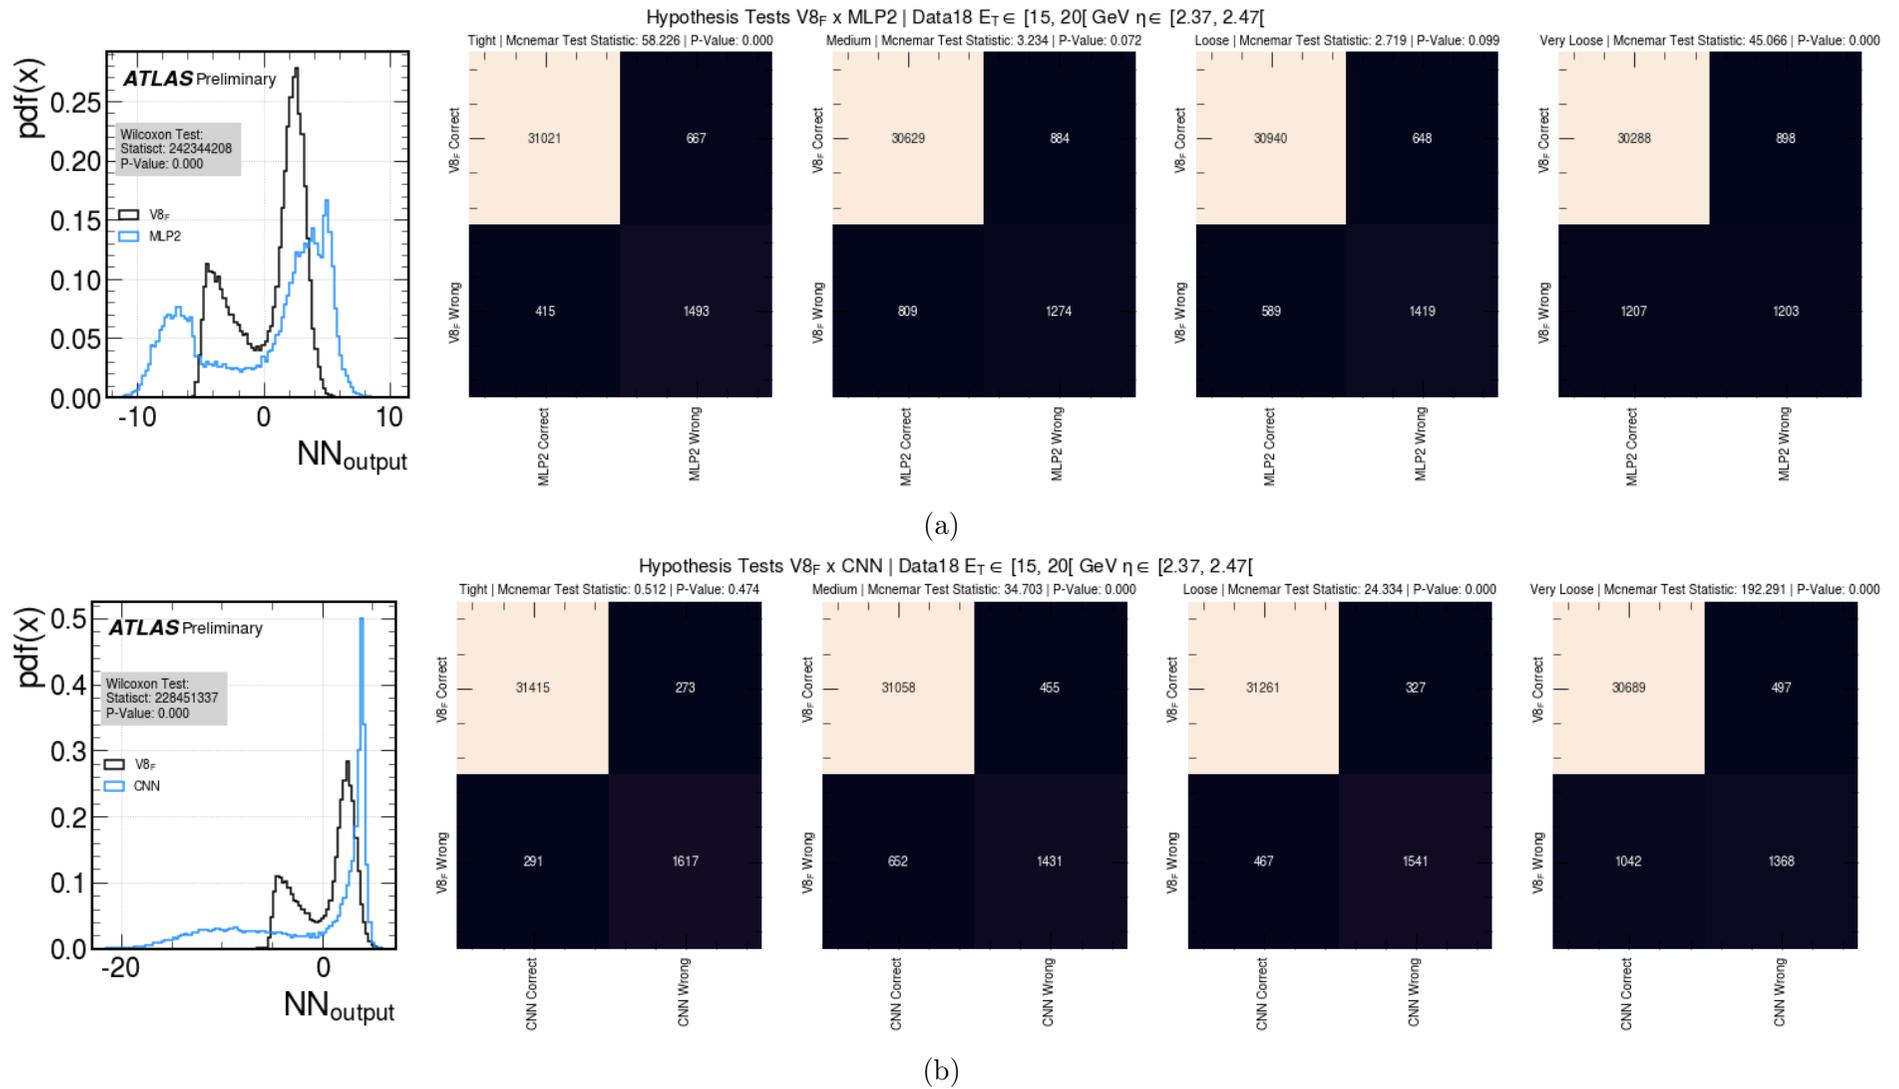


Figura 6.6: Testes estatísticos de Wilcoxon e McNemar para região $15 \leq E_T < 20$ GeV. Na Figura (a) estão as comparações entre o modelo MLP2 e $V8_F$ e na Figura (b) está a comparação entre o modelo CNN e o $V8_F$.

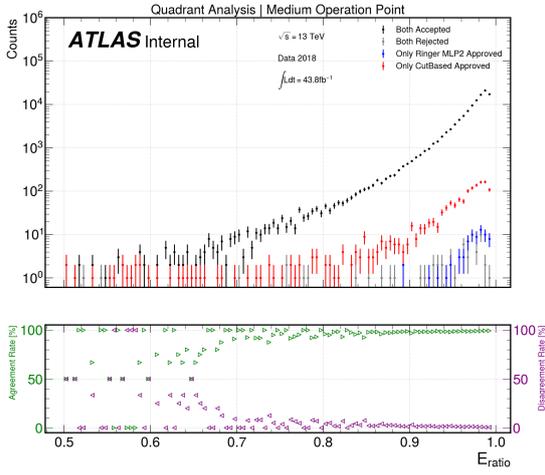
6.4 Análise de Quadrante

A análise de quadrante possibilita avaliar o acordo e o desacordo entre dois modelos de seleção de elétrons. Dada a resposta de dois classificadores A e B, apenas um dos seguintes casos pode acontecer: ambos os classificadores aceitam (caso 1); ambos classificadores rejeitam (caso 2); apenas o classificador A aceita (caso 3); ou apenas o classificador B aceita (caso 4). Estes casos são mutuamente exclusivos e podem ser visualizados através de variáveis padrões da calorimetria descritas na Tabela 4.3. A partir desta análise é possível verificar em quais regiões existe o maior acordo (ou desacordo) entre os classificadores.

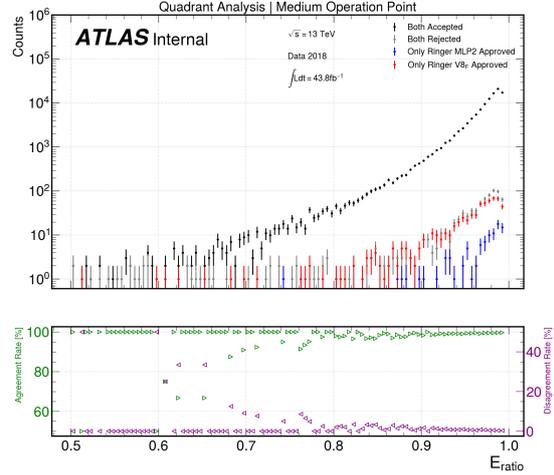
Na Figura 6.7 estão as comparações entre os classificadores para a operação *Medium* nos dados de sinal obtidos em 2018 para a variável E_{ratio} . Espera-se que o valor do E_{ratio} para um elétron seja próximo de 1 e isto é observado em cada uma das comparações, visto que o resultado dos classificadores se concentra nesta região. Entretanto, nota-se que os modelos MLP2 e CNN coletam menos amostras do que os modelos $V8_F$ e o *CutBased*, apesar da taxa de desacordo na região próxima de 1 ser inferior a 5% para todas as comparações. A análise de quadrante indica que a modificação feita no modelo $V8_F$ acarretou em um aumento no P_D .

Outra variável avaliada foi a R_η (Figura 6.8). Assim como no caso da variável E_{ratio} , espera-se que o valor da variável R_η esteja próximo de 1 para a distribuição do sinal. As comparações realizadas a partir desta variável indicam que o modelo CNN e o modelo MLP2 coletam mais elétrons com valores próximos à 1 do que o *CutBased* (Vide Figuras 6.8c e 6.8a). Entretanto, quando comparados estes modelos entre si foi observado que a MLP2 coleta mais elétrons do que a CNN. Os desacordos, por sua vez, mantiveram-se abaixo de 5%.

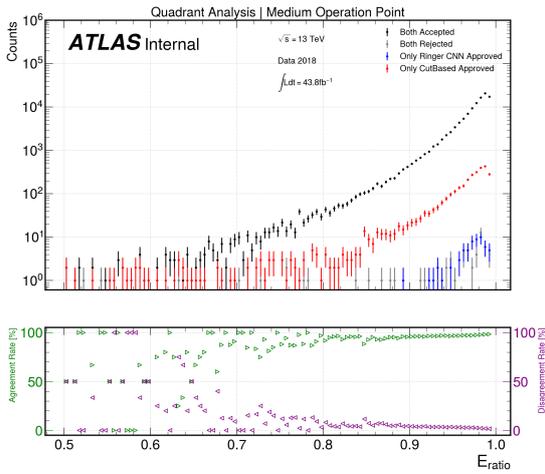
A última variável avaliada foi a variável R_{had} (Figura 6.9). Chamada de *hadronic leakage* esta variável mede a quantidade de energia hadrônica contida em um chuveiro e espera-se que elétrons possuam valores próximos de 0 para esta variável. Novamente é obtido um alto nível de acordo entre os classificadores, porém nota-se que o modelo CNN possui uma queda mais acentuada para valores positivos da variável (Figura 6.8c), este tipo de comportamento também foi observado no modelo MLP2 porém de forma mais discreta. Como esperado, o $V8_F$ coleta mais amostras na região próxima de 0, todavia as amostras selecionadas possuem maior vazamento hadrônico (Figuras 6.9e e 6.9d). Os desacordos na região próximo a 0 são da ordem de 5%.



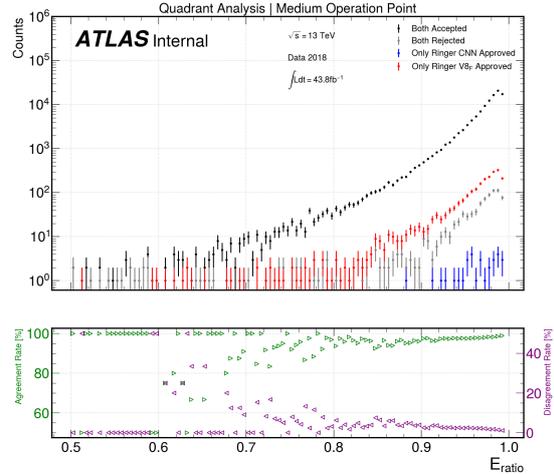
(a) Comparação MLP2 com *CutBased*



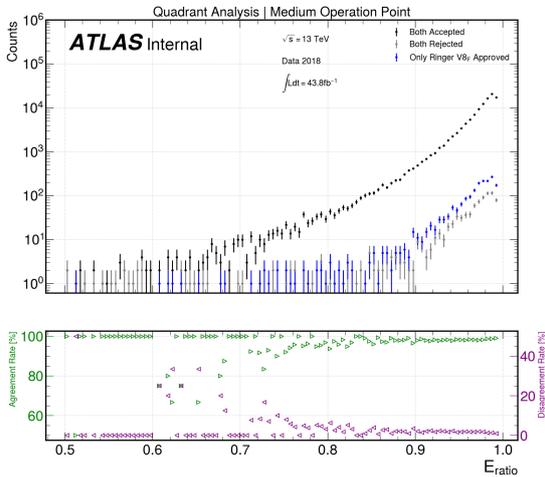
(b) Comparação MLP2 com $V8_F$



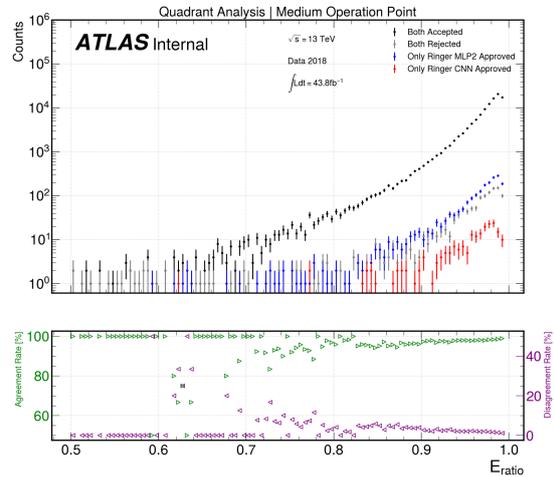
(c) Comparação CNN com *CutBased*



(d) Comparação CNN com $V8_F$

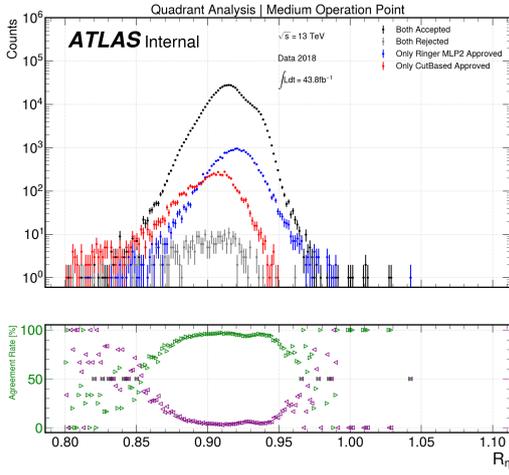


(e) Comparação $V8_F$ com $V8$

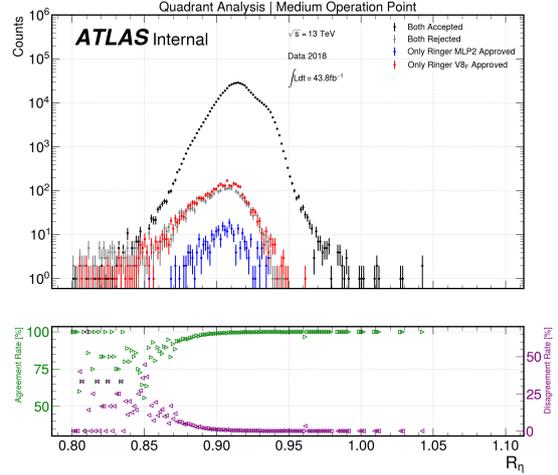


(f) Comparação MLP2 com CNN

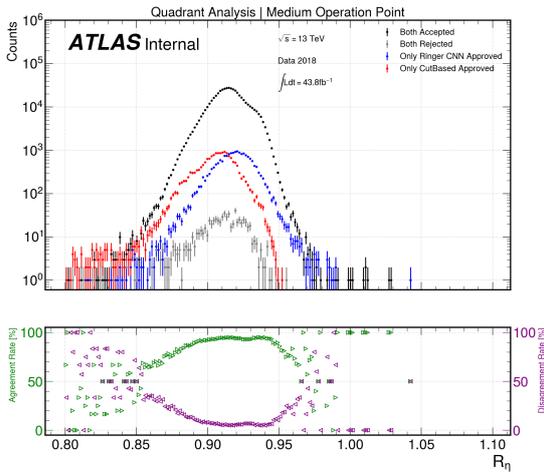
Figura 6.7: Análise de quadrante para o critério *Medium* em dados de 2018 para a variável E_{ratio} . As comparações foram realizadas em duplas para os modelos MLP2, CNN, V8, $V8_F$ e *CutBased*. A análise de quadrante foi obtida com elétrons (pósitrons) do decaimento do bóson Z através do método T&P. O *probe* reconstruído deve estar na região mais externa do ATLAS ($2,37 \leq |\eta| < 2,47$). Em preto encontra-se o caso 1; em azul o caso 2; em vermelho o caso 3 e em cinza o caso 4. Na parte inferior, em verde, esta a taxa de acordo entre estratégias (caso 1 + caso 2) e em roxo está o desacordo entre as mesmas (caso 3 + caso 4).



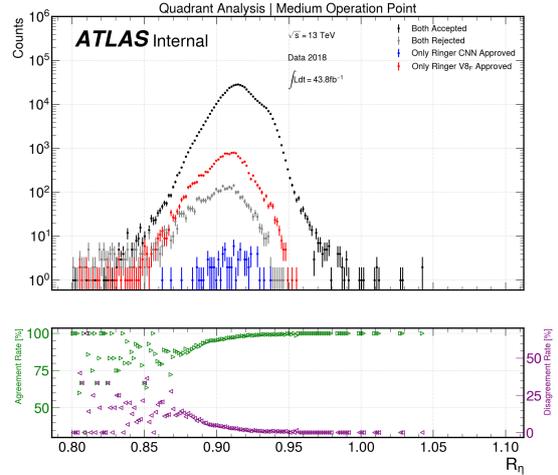
(a) Comparação MLP2 com *CutBased*



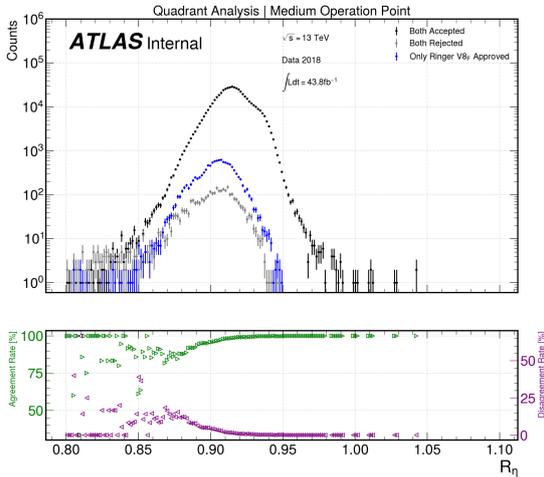
(b) Comparação MLP2 com *V8_F*



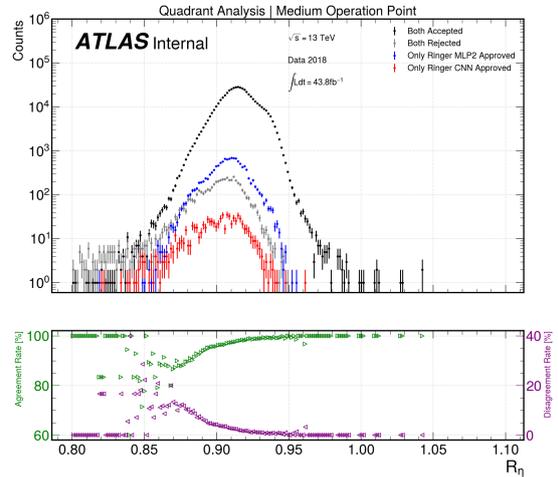
(c) Comparação CNN com *CutBased*



(d) Comparação CNN com *V8_F*

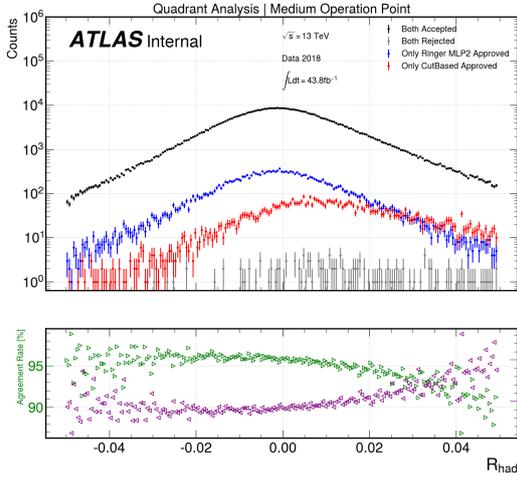


(e) Comparação *V8_F* com *V8*

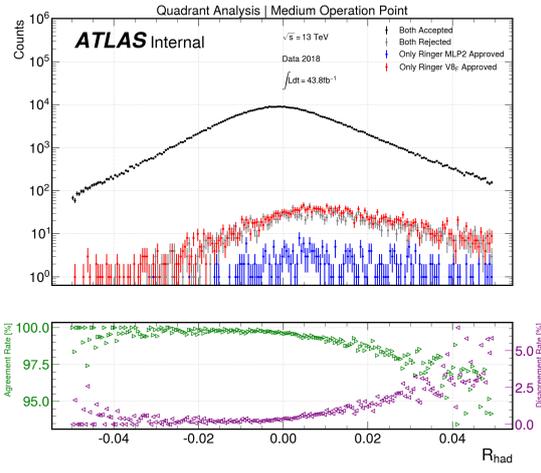


(f) Comparação MLP2 com CNN

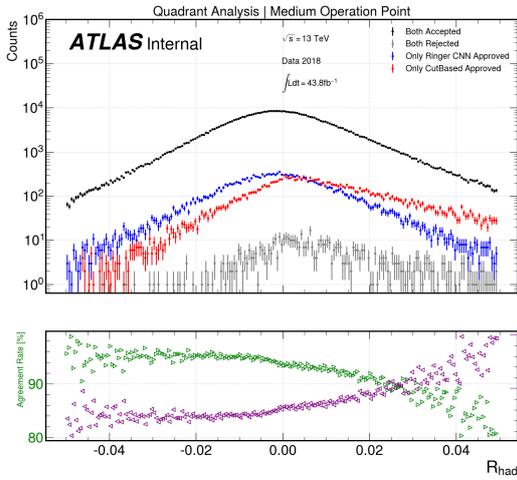
Figura 6.8: Análise de quadrante para o critério *Medium* em dados de 2018 para a variável R_η . As comparações foram realizadas em duplas para os modelos MLP2, CNN, V8, $V8_F$ e *CutBased*. A análise de quadrante foi obtida com elétrons (pósitrons) do decaimento do bóson Z através do método T&P. O *probe* reconstruído deve estar na região mais externa do ATLAS ($2,37 \leq |\eta| < 2,47$). Em preto encontra-se o caso 1; em azul o caso 2; em vermelho o caso 3 e em cinza o caso 4. Na parte inferior em verde está a taxa de acordo entre estratégias (caso 1 + caso 2) e em roxo está o desacordo entre as mesmas (caso 3 + caso 4).



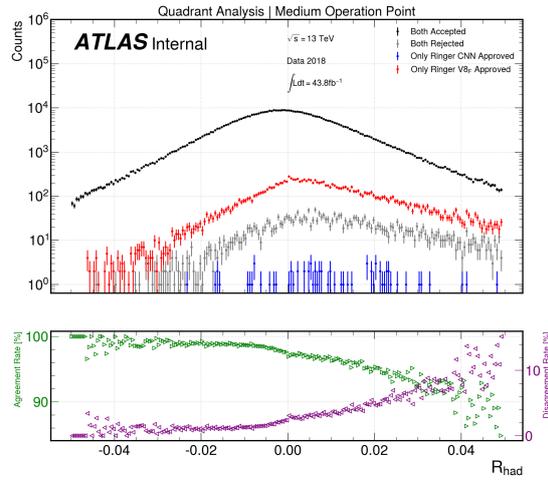
(a) Comparação MLP2 com *CutBased*



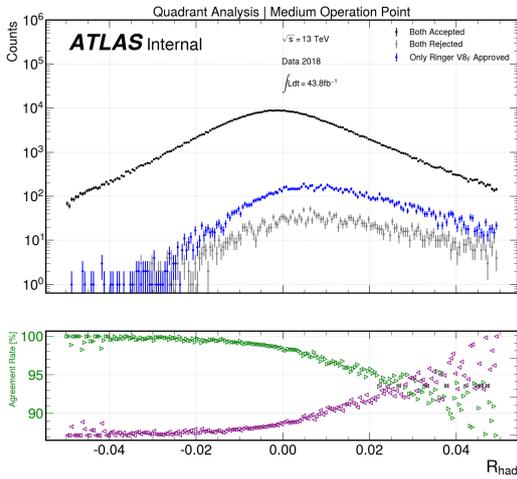
(b) Comparação MLP2 com $V8_F$



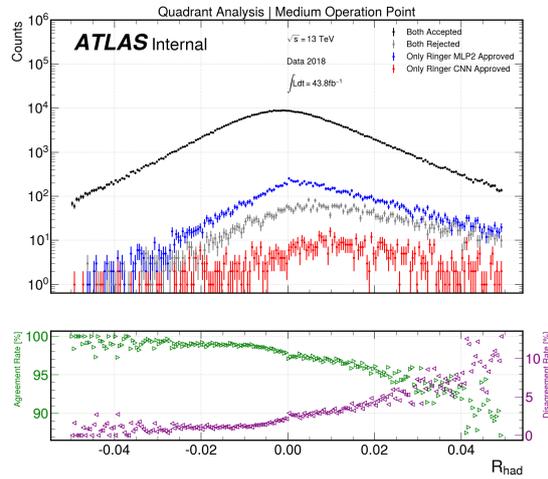
(c) Comparação CNN com *CutBased*



(d) Comparação CNN com $V8_F$



(e) Comparação $V8_F$ com $V8$

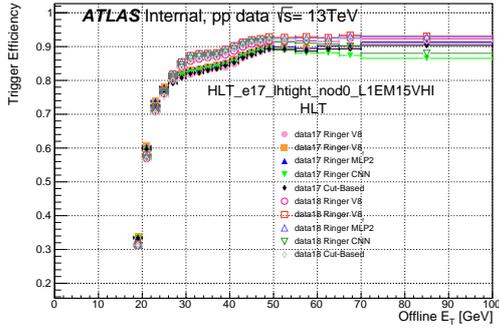


(f) Comparação MLP2 com CNN

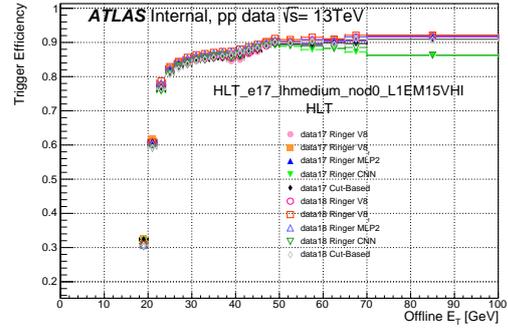
Figura 6.9: Análise de quadrante para o critério *Medium* em dados de 2018 para a variável R_{had} . As comparações foram realizadas em duplas para os modelos MLP2, CNN, $V8$, $V8_F$ e *CutBased*. A análise de quadrante foi obtida com elétrons (pósitrons) do decaimento do bóson Z através do método T&P. O *probe* reconstruído deve estar na região mais externa do ATLAS ($2,37 \leq |\eta| < 2,47$). Em preto encontra-se o caso 1; em azul o caso 2; em vermelho o caso 3 e em cinza o caso 4. Na parte inferior em verde esta a taxa de acordo entre estratégias (caso 1 + caso 2) e em roxo está o desacordo entre as mesmas (caso 3 + caso 4).

6.5 Emulação das Cadeias de Filtragem

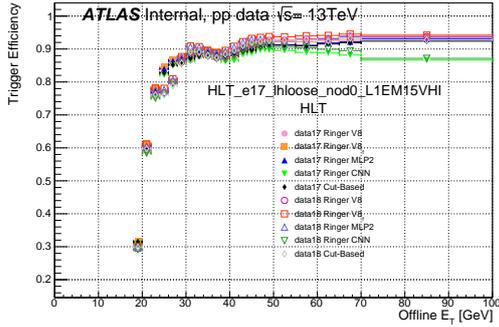
O processo de emulação local das cadeias descritas na Tabela 5.4 foi realizado e o P_D e o P_F para as etapas **FastCalo** e **HLT** estão dispostos na Tabela 6.7. Para as cadeias com operação *Tight* e *Medium* os resultados indicam que os modelos **MLP2** e **CNN** conseguiram operar mantendo a eficiência ao final do **HLT** próxima à do *CutBased*, o que é um requisito para operação no **Trigger** [26]. As diferenças em função de P_D para estas cadeias são de $\approx \pm 1$ ponto percentual, o que é admissível para operação. Na Figura 6.10b é possível observar a eficiência da cadeia em função da E_T . O modelo **CNN** tem quedas na eficiência para $E_T > 60$ tanto para amostras de 2017 quanto para amostras de 2018. Esta queda é menor em relação a cadeia *Tight* (vide Figura 6.10a). Entretanto nas operações *Loose* e *Very Loose* as diferenças cresceram para $\approx \pm 2$ pontos percentuais para as cadeias que operaram com o modelo **CNN** o que indica a necessidade de reajuste dos patamares.



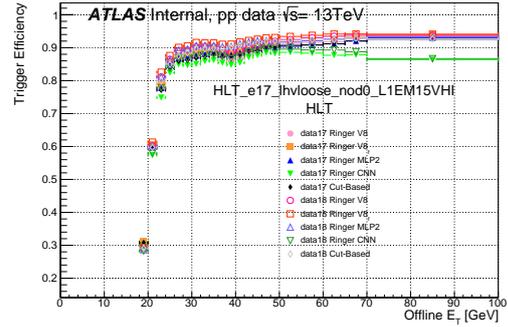
(a) *Tight*



(b) *Medium*



(c) *Loose*

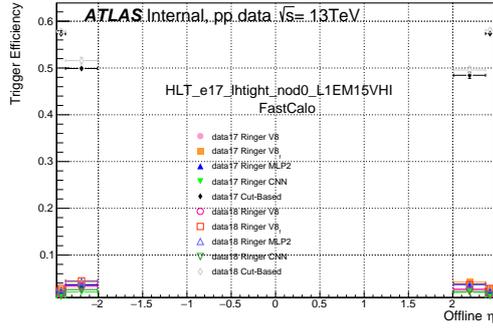


(d) *Very Loose*

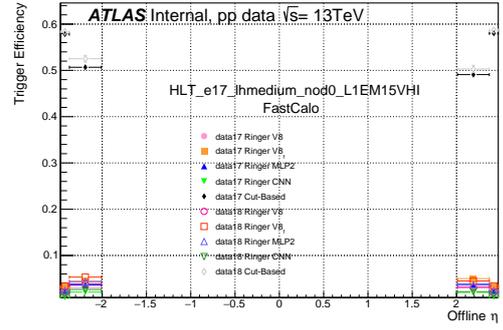
Figura 6.10: Eficiência das cadeias em função de E_T para as diferentes operações.

O P_F das cadeias é substancialmente reduzido na etapa **FastCalo** quando comparado com o *CutBased* enquanto a **MLP2** obtém valores próximos aos obtidos pelo $V8_F$. Embora a **CNN** tenha o menor P_F entre todas as estratégias, a mesma não obteve os valores de P_D necessário para operação nos critérios *Loose* e *Very Loose*. Na Figura 6.11 é possível observar que todos os modelos com a exceção do *CutBased*

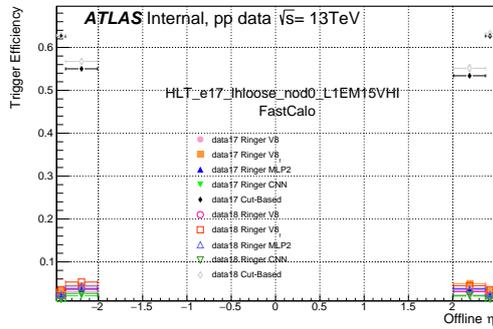
possuem P_F menores do que 10%.



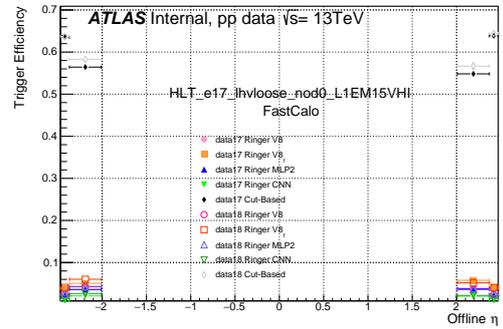
(a) *Tight*



(b) *Medium*



(c) *Loose*



(d) *Very Loose*

Figura 6.11: P_F das cadeias em função de η para as diferentes operações.

Tabela 6.7: Resultados da emulação das cadeias de [Trigger](#) utilizando dados de 2017 e 2018.

Assinaturas	Seleção no FastCalo	Periodo de colisão	$Z \rightarrow ee$		Jatos		
			FastCalo [%]	HLT [%]	FastCalo [%]	HLT [%]	
HLT_e17_lhtight_nod0_L1EM15VHI	Cut-Based	2017	95,26	82,88	56,74	0,02	
		2018	95,05	85,49	56,74	0,24	
	Ringer V8	2017	94,49	82,76	1,43	0,01	
		2018	94,36	85,38	1,71	0,07	
	Ringer V8 _F	2017	96,52	83,94	2,73	0,02	
		2018	96,39	86,74	2,94	0,10	
	Ringer MLP2	2017	96,39	83,91	2,26	0,02	
		2018	96,29	86,69	2,52	0,09	
	Ringer CNN	2017	94,91	82,99	1,13	0,01	
		2018	94,81	85,69	1,47	0,05	
	HLT_e17_lhmedium_nod0_L1EM15VHI	Cut-Based	2017	94,97	83,96	57,35	0,05
			2018	94,97	84,64	58,03	0,13
Ringer V8		2017	94,43	84,29	1,81	0,02	
		2018	94,43	84,75	2,10	0,09	
Ringer V8 _F		2017	96,41	85,54	3,34	0,03	
		2018	96,26	86,02	3,54	0,11	
Ringer MLP2		2017	96,03	85,35	2,26	0,03	
		2018	95,89	85,35	2,52	0,09	
Ringer CNN		2017	93,88	83,96	1,13	0,01	
		2018	93,76	84,43	1,47	0,06	
HLT_e17_lhloose_nod0_L1EM15VHI		Cut-Based	2017	94,65	86,36	62,02	0,33
			2018	94,43	86,61	62,53	0,93
	Ringer V8	2017	93,85	86,11	1,83	0,17	
		2018	93,72	86,49	2,11	0,49	
	Ringer V8 _F	2017	96,05	87,60	3,38	0,24	
		2018	95,89	88,03	3,61	0,65	
	Ringer MLP2	2017	95,40	87,18	2,26	0,19	
		2018	95,24	87,59	2,52	0,52	
	Ringer CNN	2017	92,53	85,20	1,13	0,11	
		2018	92,44	85,55	1,47	0,34	
	HLT_e17_lhvloose_nod0_L1EM15VHI	Cut-Based	2017	94,49	86,09	63,11	0,54
			2018	94,27	88,05	63,63	1,33
Ringer V8		2017	94,27	86,04	2,28	0,32	
		2018	93,72	87,99	2,28	0,78	
Ringer V8 _F		2017	95,89	87,38	4,06	0,42	
		2018	95,75	89,54	4,21	1,00	
Ringer MLP2		2017	94,62	86,63	2,26	0,31	
		2018	94,54	88,66	2,26	0,77	
Ringer CNN		2017	90,88	84,06	1,13	0,18	
		2018	90,91	85,74	1,47	0,51	

Capítulo 7

Conclusões e trabalhos futuros

A física experimental e de altas energias proporciona um ambiente ímpar para o desenvolvimento de técnicas de Inteligência Computacional devido as suas características como a alta segmentação da informação nos experimentos, a elevada taxa de eventos e problemas de empilhamento de sinais.

Este trabalho desenvolveu uma redução sintética da granularidade da informação dos anéis do *NeuralRinger* com objetivo de simular as condições de um *Trigger* de elétrons na região de alta pseudorapidez do calorímetro tendo em vista uma possível extensão do sistema de filtragem para a região com $|\eta| > 2,5$. Para isso foram treinados dois tipos de classificadores, [MLP](#) e [CNN](#) como estratégias de seleção da etapa [FastCalo](#) com base apenas na calorimetria sendo os mesmos comparados com o *NeuralRinger* padrão e uma versão onde as entradas são modificadas e os anéis removidos na abordagem deste trabalho tem seus valores zerados.

Os resultados obtidos demonstram que embora os modelos tenham produzido saídas bem diferentes entre si, a eficiência foi mantida para a maioria dos critérios empregados. Com relação ao P_F foi observado a redução do mesmo em relação à estratégia *CutBased*, enquanto o modelo [MLP2](#) atingiu performance similar ao modelo *V8* mesmo tendo apenas 2 neurônios na camada escondida. Embora a escolha pelos melhores modelos da validação cruzada tenha feito uso apenas do [SP](#) esta escolha não leva em consideração a qualidade do ajuste em função de $\langle\mu\rangle$, motivando o estudos de um método de seleção que também priorize um melhor ajuste em função de $\langle\mu\rangle$.

Os testes estatísticos de Wilcoxon e de McNemar possibilitaram avaliar a hipótese de que os modelos treinados neste trabalho diferem do modelo *V8_F*, com relação à saída do classificador e a decisão para os diferentes níveis de operação. Tais diferenças também são explicitadas na análise de quadrante, onde o modelo [CNN](#), apesar do alto nível de acordo com o modelo *V8_F*, coletou menos amostras na região esperada para a variável E_{ratio} . Todavia, do ponto de vista das variáveis que representam o vazamento em η e o vazamento hadrônico, o modelo [CNN](#) aceitou

elétrons com menos vazamentos do que as outras estratégias.

Os resultados de emulação das *chains* da Tabela 5.4 mostram que para critérios menos restritos o modelo CNN tem seu P_D reduzido o que é um problema do ponto de vista do Trigger. Com relação aos critérios mais restritivos ambos os modelos, MLP2 e CNN obtiveram resultados promissores atingindo a operação necessária para o HLT e com baixos níveis de P_F . Posto isto, é necessário reajustar os pontos de operação para os critérios menos restritivos do modelo CNN a fim de atingir os níveis de operação determinados pelo Trigger.

7.1 Trabalhos futuros

Este é um trabalho em andamento. Os resultados obtidos indicam a possibilidade da aplicação do *NeuralRinger* em regiões de baixa granularidade. Entretanto, a ausência de seleção do *L1Calo* para região com $|\eta| > 2,5$ é o maior impedimento para a construção dos anéis *online* e o desenvolvimento do Trigger para região *Forward*.

O modelo de aprendizado profundo desenvolvido neste trabalho teve dificuldade para manter a eficiência exigida pelo HLT nos critérios menos restritivos *Loose* e *Very Loose* durante a emulação das cadeias de filtragem. A comparação entre os modelos nestes critérios não pode ser realizada, uma vez que o modelo CNN não está ajustado para operar com o P_D necessário. Assim, um estudo deve ser realizado com o objetivo de reajustar os patamares destes critérios para o modelo CNN visando atingir a eficiência imposta.

Outra maneira de simular a granularidade da região *Forward* seria remover as camadas PS e EM3 e agrupar os anéis das camadas restantes para criar um efeito que simule, não só a ausência de camadas dos calorímetros na região *Forward* (em comparação com a região do barril), mas também a granularidade mais grosseira e característica da região de alta pseudorapidez.

Referências Bibliográficas

- [1] EVANS, L., BRYANT, P. “LHC machine”, *Journal of instrumentation*, v. 3, n. 08, pp. S08001, 2008.
- [2] NOBELPRIZE.ORG. “The Nobel Prize in Physics 2013”. Disponível em: <<https://www.nobelprize.org/prizes/physics/2013/summary/>>. Acesso em: 17 de Fevereiro de 2022.
- [3] ENGLERT, F., BROUT, R. “Broken symmetry and the mass of gauge vector mesons”, *Physical review letters*, v. 13, n. 9, pp. 321, 1964.
- [4] HIGGS, P. W. “Broken symmetries, massless particles and gauge fields”, *Phys. Lett.*, v. 12, pp. 132–133, 1964.
- [5] AAD, G., ABAJYAN, T., ABBOTT, B., et al. “Observation of a new particle in the search for the Standard Model Higgs boson with the ATLAS detector at the LHC”, *Physics Letters B*, v. 716, n. 1, pp. 1–29, 2012.
- [6] CHATRCHYAN, S., KHACHATRYAN, V., SIRUNYAN, A. M., et al. “Observation of a new boson at a mass of 125 GeV with the CMS experiment at the LHC”, *Physics Letters B*, v. 716, n. 1, pp. 30–61, 2012.
- [7] AIRAPETIAN, A., DODONOV, V., MICU, L., et al. *ATLAS detector and physics performance: Technical Design Report, 1*. ATLAS CERN-LHCC-99-014, 1999. Disponível em: <<http://cds.cern.ch/record/391176>>. Acesso em: 14 de setembro de 2022.
- [8] AIRAPETIAN, A., DODONOV, V., MICU, L., et al. *ATLAS detector and physics performance: Technical Design Report, 2*. ATLAS CERN-LHCC-99-015, 1999. Disponível em: <<http://cds.cern.ch/record/391177>>. Acesso em: 14 de setembro de 2022.
- [9] JENNI, P., NESSI, M., NORDBERG, M., et al. *ATLAS high-level trigger, data-acquisition and controls: Technical Design Report*. Relatório técnico, Geneva, 2003. Disponível em: <<http://cds.cern.ch/record/616089>>. Acesso em: 14 de setembro de 2022.

- [10] AAD, G., ABBOTT, B., ABBOTT, D. C., et al. “Performance of electron and photon triggers in ATLAS during LHC Run 2”, *The European Physical Journal C*, v. 80, n. 1, pp. 1–41, 2020.
- [11] CARUSO, F., SANTORO, A. “Do átomo Grego à Física das interações fundamentais”, *Rio de Janeiro: AIAFEX*, 1994.
- [12] CARUSO, F., OGURI, V. *Física moderna: origens clássicas e fundamentos quânticos*. San Diego, CA, Elsevier, 2006.
- [13] MARTIN, B. R. *Nuclear and particle physics: an introduction; 2nd ed.* 2 ed. Hoboken, NJ, Wiley, 2009.
- [14] ABDALLA, M. C. B. *O discreto charme das partículas elementares*. Unesp, 2006.
- [15] ENDLER, A. M. F. *Introdução à Física de Partículas*. Livraria da Física, 2010.
- [16] *ATLAS calorimeter performance: Technical Design Report*. Relatório técnico, Geneva, 1996. Disponível em: <<http://cds.cern.ch/record/331059>>. Acesso em: 14 de setembro de 2022.
- [17] *ATLAS liquid-argon calorimeter: Technical Design Report*. Relatório técnico, Geneva, 1996. Disponível em: <<http://cds.cern.ch/record/331061>>. Acesso em: 14 de setembro de 2022.
- [18] WIGMANS, R., WIGMANS, R. *Calorimetry: Energy measurement in particle physics*, v. 107. Oxford University Press, 2000.
- [19] *ATLAS inner detector: Technical Design Report, 1*. Relatório técnico, Geneva, 1997. Disponível em: <<http://cds.cern.ch/record/331063>>. Acesso em: 14 de setembro de 2022.
- [20] HAYWOOD, S., ROSSI, L., NICKERSON, R., et al. *ATLAS inner detector: Technical Design Report, 2*. Relatório técnico, Geneva, 1997. Disponível em: <<http://cds.cern.ch/record/331064>>. Acesso em: 14 de setembro de 2022.
- [21] FREUND, W. *Identificação de Elétrons Baseada em um Calorímetro de Altas Energias Finamente Segmentado*. Tese de D.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, 2018.
- [22] ARAÚJO, M. *Filtragem Online Baseada em Calorimetria de Altas Energias e com Alta Taxa de Eventos*. Dissertação de M.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, 2022.

- [23] PINTO, J. V. F. “Sistema neural para filtragem online em um detector finalmente segmentado”. 2016.
- [24] SEIXAS, J., CALOBA, L., SOUZA, M., et al. “Neural second-level trigger system based on calorimetry”, *Computer Physics Communications*, v. 95, n. 2-3, pp. 143–157, 1996.
- [25] D’ENTERRIA, D. “Forward Physics at the LHC: within and beyond the Standard Model”, *Brazilian Journal of Physics*, v. 38, n. 3B, pp. 381–390, 2008.
- [26] PINTO, J. V. D. F. *Filtragem Online Segmentada Baseada em Redes Neurais Operando na Informação de um Calorímetro de Altas Energias de Fina Granularidade*. Tese de D.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, 2022.
- [27] EHRKE, L. F. *Electron Identification using Deep Neural Networks*. Relatório técnico, CERN, Geneva, 2020. Disponível em: <<https://cds.cern.ch/record/2746051>>.
- [28] ARBUZOV, A. “Quantum Field Theory and the Electroweak Standard Model”, pp. 1–34. 35 p, Jan 2018. doi: 10.23730/CYRSP-2017-004.1. Disponível em: <<https://cds.cern.ch/record/2315477>>. 35 pages.
- [29] LATTES, C. M., MUIRHEAD, H., OCCHIALINI, G. P., et al. “Processes involving charged mesons”, *Nature*, v. 159, n. 4047, pp. 694–697, 1947.
- [30] PESKIN, M. E. *An introduction to quantum field theory*. CRC Press, 2018.
- [31] PEQUENAO, J. “Event Cross Section in a computer generated image of the ATLAS detector.” Mar 2008. Disponível em: <<http://cds.cern.ch/record/1096081>>. Acesso em: 1 de outubro de 2022.
- [32] *The High-Luminosity LHC Project. 298th Meeting of Scientific Policy Committee*. Relatório técnico, 2016. Disponível em: <<https://cds.cern.ch/record/2199189>>.
- [33] ORR, R. S., COLLABORATION, A. L. A. “The ATLAS Forward Calorimeter”. In: *Astroparticle, Particle, Space Physics and Detectors for Physics Applications*, World Scientific, pp. 780–786, 2012.
- [34] DRELL, S. D., YAN, T.-M. “Massive lepton-pair production in hadron-hadron collisions at high energies”, *Physical Review Letters*, v. 25, n. 5, pp. 316, 1970.

- [35] BRUCE, R., SALVANT, B., PIELONI, T., et al. *LHC Run 2: Results and challenges*. Relatório técnico, 2016.
- [36] ALBRECHT, J., GLIGOROV, V., RAVEN, G., et al. “Performance of the LHCb high level trigger in 2012”. In: *Journal of Physics: Conference Series*, v. 513, p. 012001, 2014.
- [37] SCHRAMM, S. *Machine learning at CERN: ATLAS, LHCb, and more*. Relatório técnico, ATL-COM-PHYS-2018-820, 2018.
- [38] COLLABORATION, C., OTHERS. “Identification of b-quark jets with the CMS experiment”, *Journal of Instrumentation*, v. 8, n. 04, pp. P04013, 2013.
- [39] BOLS, E., KIESELER, J., VERZETTI, M., et al. “Jet flavour classification using DeepJet”, *Journal of Instrumentation*, v. 15, n. 12, pp. P12012, 2020.
- [40] CUTTS, D., HOFTUN, J. S., SORNBORGER, A., et al. “Neural Networks for event filtering at D0”, *Computer Physics Communications*, v. 57, n. 1–3, pp. 478 – 482, 1989. ISSN: 0010-4655. doi: [http://dx.doi.org/10.1016/0010-4655\(89\)90267-1](http://dx.doi.org/10.1016/0010-4655(89)90267-1). Disponível em: <<http://www.sciencedirect.com/science/article/pii/0010465589902671>>. Acesso em: 15 de setembro de 2022.
- [41] ABE, K., AHRENS, L., AMAKO, K., et al. “Determination of $\sin^2 \theta_W$ from measurements of differential cross sections for muon-neutrino and antineutrino scattering by electrons”, *Physical Review Letters*, v. 62, n. 15, pp. 1709, 1989.
- [42] ABT, I., AHMED, T., AID, S., et al. “The H1 detector at HERA”, *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, v. 386, n. 2-3, pp. 310–347, 1997.
- [43] ZIMMERMANN, J., KIESLING, C. “Neural networks for the H1 experiment”. In: *IEEE Symposium Conference Record Nuclear Science 2004.*, v. 3, pp. 1869–1872 Vol. 3, Oct 2004. doi: 10.1109/NSSMIC.2004.1462609.
- [44] KIESLING, C., JANAUSCHEK, L., PLACAKYTE, R., et al. “The H1 neural network trigger”. In: *Intelligent Sensors, Sensor Networks and Information Processing Conference, 2004. Proceedings of the 2004*, pp. 319–324. IEEE, 2004.

- [45] JUNG, A. W., BAIRD, A., BALDINGER, R., et al. “First results from the third level of the h1 fast track trigger”. In: *Real-Time Conference, 2007 15th IEEE-NPSS*, pp. 1–7. IEEE, 2007.
- [46] ANASTOPOULOS, C., UNAL, G., BENHAR NOCCIOLI, E., et al. *Supporting document on electron identification and efficiency measurements using the 2015 LHC proton-proton collision data*. Relatório Técnico ATL-COM-PHYS-2016-041, CERN, Geneva, Jan 2016. Disponível em: <<https://cds.cern.ch/record/2125283>>. Acesso em: 14 de setembro de 2022.
- [47] AAD, G., BENTVELSEN, S., BOBBINK, G. J., et al. “The ATLAS Experiment at the CERN Large Hadron Collider”, *JINST*, v. 3, pp. S08003. 437 p, 2008. Disponível em: <<http://cds.cern.ch/record/1129811>>. Acesso em: 15 de setembro de 2022. Also published by CERN Geneva in 2010.
- [48] PEQUENAO, J. “Computer generated image of the whole ATLAS detector”, Mar 2008. Disponível em: <<https://cds.cern.ch/record/1095924>>. Acesso em: 21 de setembro de 2022.
- [49] SCHOTT, M., DUNFORD, M. “Review of single vector boson production in pp collisions at $\sqrt{s} = 7$ TeV. Review of single vector boson production in pp collisions at $\sqrt{s} = 7$ TeV”, *Eur. Phys. J. C*, v. 74, pp. 60 p, Jul 2014. doi: 10.1140/epjc/s10052-014-2916-1. Disponível em: <<https://cds.cern.ch/record/1699952>>. Comments: 60 pages, 64 figures, For Eur. Phys. J. C.
- [50] WERMES, N., HALLEWEL, G. *ATLAS pixel detector: Technical Design Report*. Relatório técnico, Geneva, 1998. Disponível em: <<http://cds.cern.ch/record/381263>>. Acesso em: 14 de setembro de 2022.
- [51] AHMAD, A., ALBRECHTSKIRCHINGER, Z., ALLPORT, P., et al. “The silicon microstrip sensors of the ATLAS semiconductor tracker”, *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, v. 578, n. 1, pp. 98–118, 2007.
- [52] ABAT, E., ADDY, T., ÅKESSON, T., et al. “The ATLAS TRT barrel detector”, *Journal of Instrumentation*, v. 3, n. 02, pp. P02014, 2008.
- [53] PEQUENAO, J. “Computer generated image of the ATLAS inner detector”, Mar 2008. Disponível em: <<https://cds.cern.ch/record/1095926>>. Acesso em: 24 de setembro de 2022.

- [54] SIMAS FILHO, E. *Análise não-linear de componentes independentes para uma filtragem online baseada em calorimetria de alta energia e com fina segmentação*. Tese de D.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, 2010.
- [55] ORR, R. S. *The ATLAS Forward Calorimeter: Construction to Physics*. Relatório técnico, CERN, Geneva, 2011. Disponível em: <<https://cds.cern.ch/record/1384503>>. This is for Como. Starts 3 Oct, talk is 4 Oct.
- [56] COLLABORATION, A. *Technical Design Report for the Phase-II Upgrade of the ATLAS TDAQ System*. Relatório Técnico CERN-LHCC-2017-020. ATLAS-TDR-029, CERN, Geneva, Sep 2017. Disponível em: <<http://cds.cern.ch/record/2285584>>. Acesso em: 14 de setembro de 2022.
- [57] COLLABORATION, A., OTHERS. “Operation of the ATLAS trigger system in Run 2”, *Journal of instrumentation*, v. 15, n. 10, pp. P10004, 2020.
- [58] RUIZ-MARTINEZ, A., COLLABORATION, A., OTHERS. “The Run-2 ATLAS Trigger System”. In: *J. Phys.: Conf. Ser.*, v. 762, p. 012003. ATL-COM-DAQ-2016-009, 2016.
- [59] VAZQUEZ, W. P., COLLABORATION, A., OTHERS. “The ATLAS data acquisition system in LHC run 2”. In: *Journal of Physics: Conference Series*, v. 898, p. 032017. IOP Publishing, 2017.
- [60] ATLAS. “ATLAS Athena Guide”. Disponível em: <<https://atlassoftwaredocs.web.cern.ch/athena/athena-intro/>>. Acesso em: 30 de setembro de 2022.
- [61] ACHENBACH, R., ADRAGNA, P., ANDREI, V., et al. “The ATLAS level-1 calorimeter trigger”, *Journal of Instrumentation*, v. 3, n. 03, pp. P03001, 2008.
- [62] SILVIA MASCIOCCHI. “Hadronic Calorimeters”. Disponível em: <https://www.physi.uni-heidelberg.de/~sma/teaching/ParticleDetectors2/sma_HadronicCalorimeters.pdf>. Acesso em: 29 de setembro de 2022.
- [63] RIEDMILLER, M., BRAUN, H. “A Direct Adaptive Method for Faster Back-propagation Learning: The RPROP Algorithm”. In: *Proceedings of the IEEE International Conference on Neural Networks*, pp. 586–591, San Francisco, USA, 1993.

- [64] NGUYEN, D., WIDROW, B. “Improving the Learning Speed of 2-Layer Neural Networks by Choosing Initial Values of the Adaptive Weights”. In: *Proceeding of the International Joint Conference on Neural Networks*, v. 3, pp. 21–26, San Diego, USA, junho 1990.
- [65] HAYKIN, S. *Neural networks: a comprehensive foundation*. Prentice Hall PTR, 2009.
- [66] ATLAS COLLABORATION. *Electron and photon energy calibration with the ATLAS detector using data collected in 2015 at $\sqrt{s} = 13$ TeV*. Relatório Técnico ATL-PHYS-PUB-2016-015, CERN, Geneva, Aug 2016. Disponível em: <<http://cds.cern.ch/record/2203514>>.
- [67] ANASTOPOULOS, C., APERIO BELLA, L., BRENDLINGER, K., et al. *Support Note for Electron ID: electron reconstruction and identification*. Relatório técnico, CERN, Geneva, 2017. Disponível em: <<https://cds.cern.ch/record/2273328>>.
- [68] AAD, G., ABBOTT, B., ABDALLAH, J., et al. “Electron performance measurements with the ATLAS detector using the 2010 LHC proton-proton collision data”, *European Physical Journal C*, v. 72, n. 3, pp. 1–46, 2012.
- [69] LAMPL, W., LOCH, P., MENKE, S., et al. *Calorimeter clustering algorithms: description and performance*. Relatório técnico, 2008.
- [70] ATLAS COLLABORATION. *Expected electron performance in the ATLAS experiment*. Relatório Técnico ATL-PHYS-PUB-2011-006, CERN, Geneva, Apr 2011. Disponível em: <<http://cds.cern.ch/record/1345327>>. Acesso em: 15 de setembro de 2022.
- [71] ADOLPHI, R., OTHERS. “The CMS experiment at the CERN LHC”, *Jinst*, v. 803, pp. S08004, 2008.
- [72] CITTOLIN, S., RÁCZ, A., SPHICAS, P. *CMS The TriDAS Project: Technical Design Report, Volume 2: Data Acquisition and High-Level Trigger. CMS trigger and data-acquisition project*. Technical Design Report CMS. Geneva, CERN, 2002. Disponível em: <<http://cds.cern.ch/record/578006>>. Acesso em: 15 de setembro de 2022.
- [73] CMS COLLABORATION AND OTHERS. “The CMS high level trigger”, *The European Physical Journal C-Particles and Fields*, v. 46, n. 3, pp. 605–667, 2006.

- [74] ZABI, A., BEAUDETTE, F., CADAMURO, L., et al. “Triggering on electrons, jets and tau leptons with the CMS upgraded calorimeter trigger for the LHC RUN II”, *Journal of Instrumentation*, v. 11, n. 02, pp. C02008, 2016.
- [75] ZABI, A., BEAUDETTE, F., CADAMURO, L., et al. “The CMS Level-1 Calorimeter Trigger for the LHC Run II”, *Journal of Instrumentation*, v. 12, n. 01, pp. C01065, 2017.
- [76] PERROTTA, A. “Performance of the CMS High Level Trigger”, *Journal of Physics: Conference Series*, v. 664, n. 8, pp. 082044, 2015. Disponível em: <<http://stacks.iop.org/1742-6596/664/i=8/a=082044>>. Acesso em: 15 de setembro de 2022.
- [77] SAUVAN, J.-B., COLLABORATION, C., OTHERS. “Performance and upgrade of the CMS electron and photon trigger for Run 2”. In: *Journal of Physics: Conference Series*, v. 587, p. 012021. IOP Publishing, 2015.
- [78] REGNARD, S. *Electron and Photon High Level Trigger in CMS for Run II*. Relatório Técnico CMS-CR-2014-124, CERN, Geneva, Jun 2014. Disponível em: <<https://cds.cern.ch/record/1754122>>. Acesso em: 15 de setembro de 2022.
- [79] AGOSTINO, L., PIERI, M. *HLT Selection of Electrons and Photons*. Relatório Técnico CMS-NOTE-2006-078, CERN, Geneva, May 2006. Disponível em: <<https://cds.cern.ch/record/962031>>. Acesso em: 15 de setembro de 2022.
- [80] CMS COLLABORATION. “Electron and photon performance in CMS with the full 2016 data sample.” Mar 2017. Disponível em: <<https://cds.cern.ch/record/2255497>>. Acesso em: 15 de setembro de 2022.
- [81] ANUAR, A. A. “Electrons and photons at High Level Trigger in CMS for Run II”. In: *Journal of Physics: Conference Series*, v. 664, p. 082001. IOP Publishing, 2015.
- [82] REMBSER, J., COLLABORATION, C., OTHERS. “CMS electron and photon performance at 13 TeV”. In: *Journal of Physics: Conference Series*, v. 1162, p. 012008. IOP Publishing, 2019.
- [83] BLAIR, R., LONG, O. R., YAO, W., et al. *The CDF-II detector: Technical design report*. Relatório técnico, 1996.

- [84] ABACHI, S., ABOLINS, M., ACHARYA, B., et al. “The D0 detector”, *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, v. 338, n. 2-3, pp. 185–253, 1994.
- [85] MEYER, A. *The CDF data acquisition system for Tevatron Run II*. Relatório técnico, Fermi National Accelerator Lab.(FNAL), Batavia, IL (United States), 2001.
- [86] KEMP, Y. *Identification of electrons in the forward region of the CDF experiment for the search for electroweak top quark production*. Tese de Doutorado, Karlsruhe U., EKP, 2006.
- [87] APOLLINARI, G. “Scintillator-strip/WLS-fiber EM shower maximum detectors in the CDF plug upgrade”, *IEEE Transactions on Nuclear Science*, v. 40, n. 4, pp. 484–489, 1993. doi: 10.1109/23.256605.
- [88] SCHWIENHORST, R., OTHERS. “The D0 run II trigger system”, *arXiv preprint physics/0411135*, 2004.
- [89] BLAZEY, G. *The d0 run ii trigger*. Relatório técnico, 1997.
- [90] ABOLINS, M., BAN, J., BYSTRICKY, J., et al. “The run IIb trigger upgrade for the DO experiment”, *IEEE Transactions on Nuclear Science*, v. 51, 06 2004. doi: 10.1109/tns.2004.828811.
- [91] LINNEMANN, J. T. *Triggering the D0 experiment*. Relatório técnico, Fermi National Accelerator Lab., Batavia, IL (United States), 1992.
- [92] CUTTS, D., HOFTUN, J. S., SORNBORGER, A., et al. “The use of neural networks in the D0 data acquisition system”, *IEEE Transactions on Nuclear Science*, v. 36, n. 5, pp. 1490–1493, 1989.
- [93] *Electron efficiency measurements with the ATLAS detector using the 2015 LHC proton-proton collision data*. Relatório Técnico ATLAS-CONF-2016-024, CERN, Geneva, Jun 2016. Disponível em: <<https://cds.cern.ch/record/2157687>>. Acesso em: 14 de setembro de 2022.
- [94] AGARAP, A. F. “Deep learning using rectified linear units (relu)”, *arXiv preprint arXiv:1803.08375*, 2018.
- [95] KINGMA, D. P., BA, J. “Adam: A method for stochastic optimization”, *arXiv preprint arXiv:1412.6980*, 2014.

- [96] TORRES, R. *Sistema online de filtragem em um ambiente com alta taxa de eventos e fina granularidade*. Tese de D.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, 2010.
- [97] RASCHKA, S. “Model evaluation, model selection, and algorithm selection in machine learning”, *arXiv preprint arXiv:1811.12808*, 2018.
- [98] YADAV, S., SHUKLA, S. “Analysis of k-fold cross-validation over hold-out validation on colossal datasets for quality classification”. In: *2016 IEEE 6th International conference on advanced computing (IACC)*, pp. 78–83. IEEE, 2016.
- [99] KING, G., ZENG, L. “Logistic Regression in Rare Events Data”, *Political Analysis*, v. 9, 09 2002. doi: 10.1093/oxfordjournals.pan.a004868.
- [100] GLOROT, X., BENGIO, Y. “Understanding the difficulty of training deep feedforward neural networks”. In: *Proceedings of the thirteenth international conference on artificial intelligence and statistics*, pp. 249–256. JMLR Workshop and Conference Proceedings, 2010.
- [101] BRUN, R., RADEMAKERS, F., CANAL, P., et al. *ROOT: An Object-Oriented Data Analysis Framework: Users Guide 5.26*. Geneva, CERN, 2009.
- [102] FIX, E., HODGES JR, J. “Significance probabilities of the Wilcoxon test”, *The Annals of Mathematical Statistics*, pp. 301–312, 1955.
- [103] WILCOXON, F. “Individual Comparisons by Ranking Methods”, *Biometrics Bulletin*, v. 1, n. 6, pp. 80–83, 1945. ISSN: 00994987. Disponível em: <<http://www.jstor.org/stable/3001968>>.
- [104] MCNEMAR, Q. “Note on the sampling error of the difference between correlated proportions or percentages”, *Psychometrika*, v. 12, n. 2, pp. 153–157, jun. 1947. doi: 10.1007/bf02295996. Disponível em: <<https://doi.org/10.1007/bf02295996>>.
- [105] EDWARDS, A. L. “Note on the “correction for continuity” in testing the significance of the difference between correlated proportions”, *Psychometrika*, v. 13, n. 3, pp. 185–187, 1948.

Apêndice A

Resultados dos Testes de Hipóteses

Neste apêndice encontram-se as ilustrações para o testes de hipótese de Wilcoxon e McNemar para todas as regiões do *ensemble*.

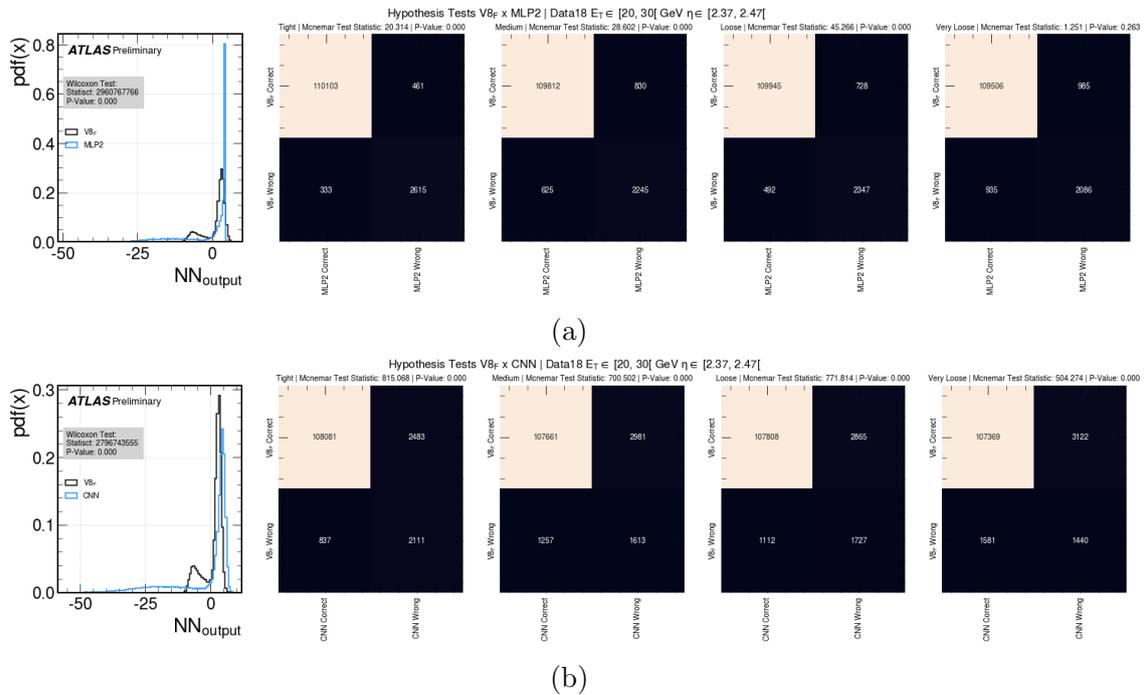
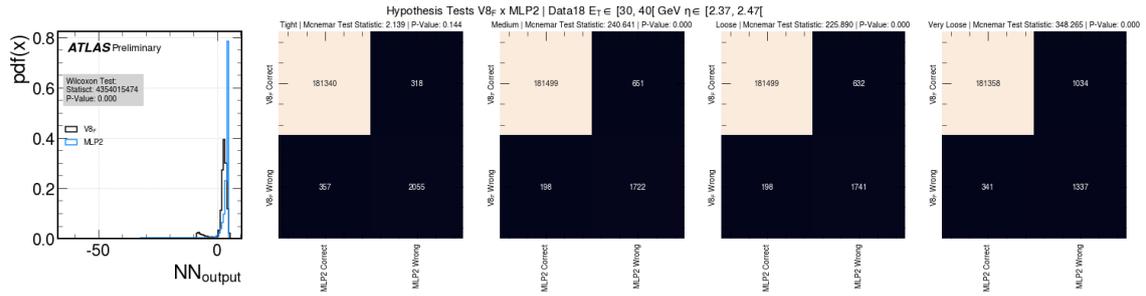
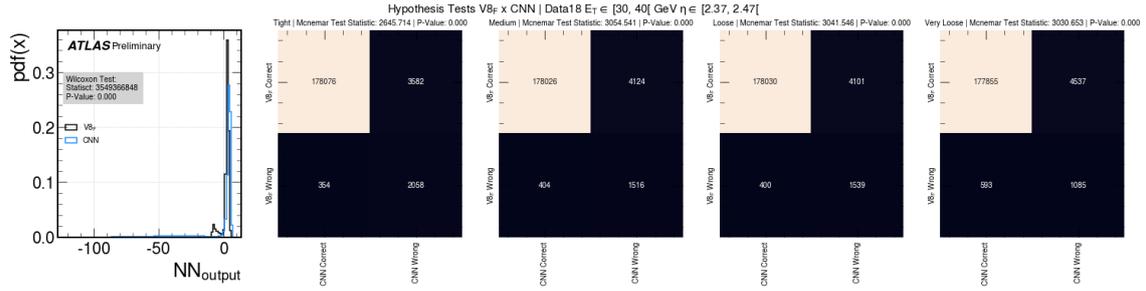


Figura A.1: Testes estatísticos de Wilcoxon e McNemar para região $20 \leq E_T < 30$. Na Figura (a) estão as comparações entre o modelo **MLP2** e $V8_F$ e na Figura (b) está a comparação entre o modelo **CNN** e o $V8_F$.

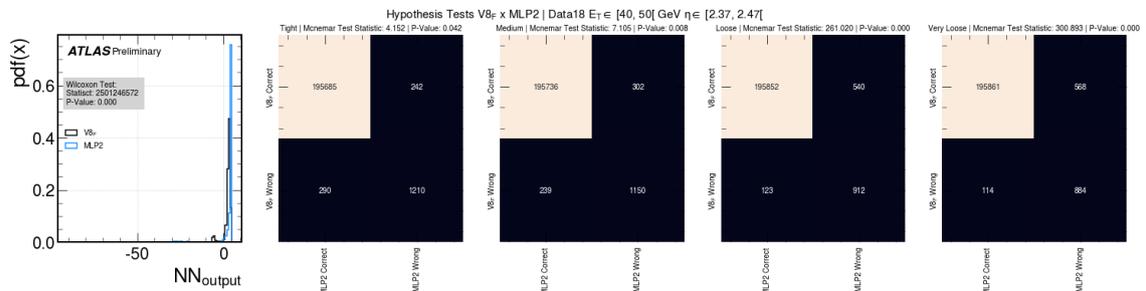


(a)

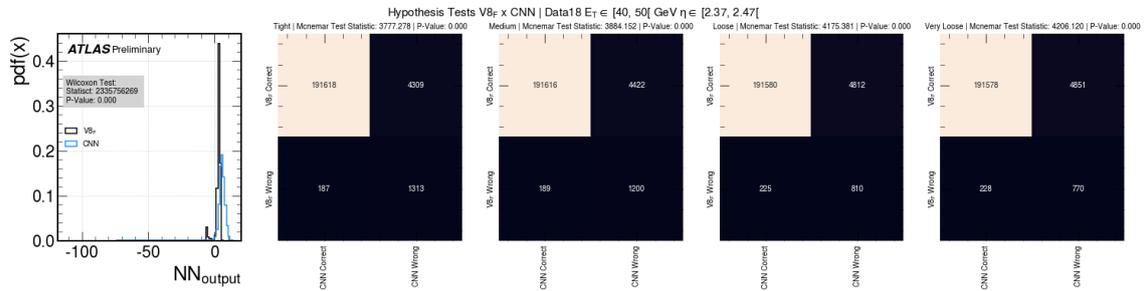


(b)

Figura A.2: Testes estatísticos de Wilcoxon e McNemar para região $30 \leq E_T < 40$ GeV. Na Figura (a) estão as comparações entre o modelo MLP2 e $V8_F$ e na Figura (b) está a comparação entre o modelo CNN e o $V8_F$.



(a)



(b)

Figura A.3: Testes estatísticos de Wilcoxon e McNemar para região $40 \leq E_T < 50$ GeV. Na Figura (a) estão as comparações entre o modelo MLP2 e $V8_F$ e na Figura (b) está a comparação entre o modelo CNN e o $V8_F$.

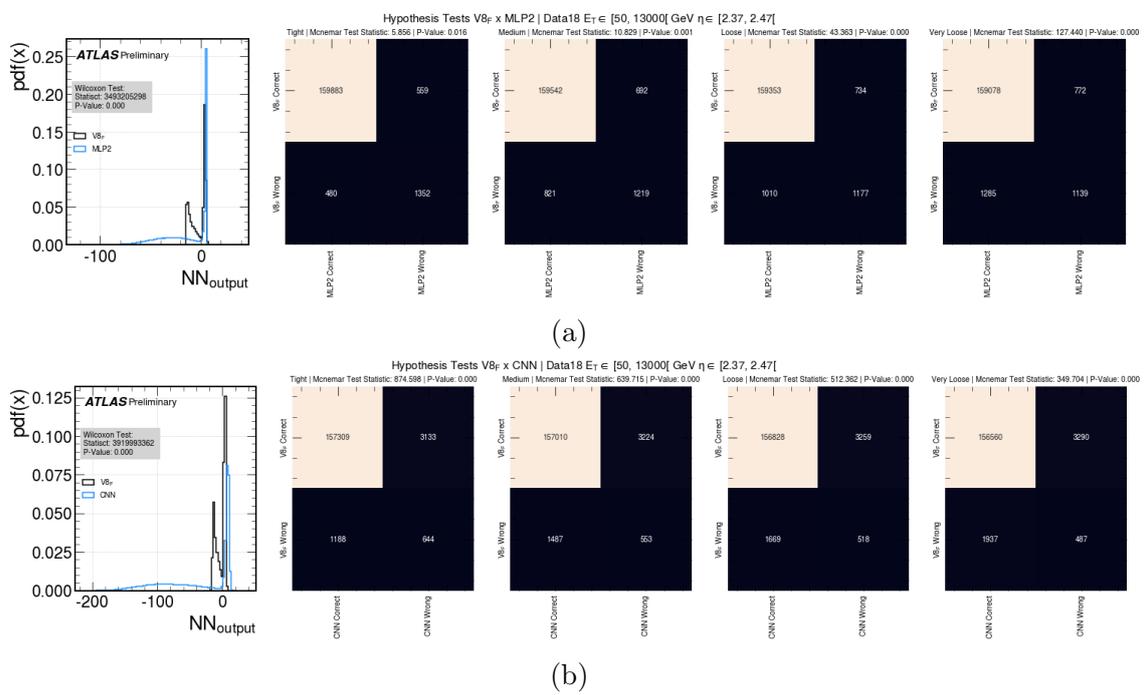


Figura A.4: Testes estatísticos de Wilcoxon e McNemar para região $E_T \geq 50$ GeV. Na Figura (a) estão as comparações entre o modelo MLP2 e $V8_F$ e na Figura (b) está a comparação entre o modelo CNN e $V8_F$.

Apêndice B

Produção Acadêmica

Abaixo estão listadas as produções acadêmicas publicadas durante o mestrado.

B.1 Resumos Publicados em Anais de Congresso

1. Ferreira, I.S.; Pinto, J.V.F.; Araújo, M.V.; Seixas, J.M. “Identificação *Online* de Elétrons da Região *Forward* do Calorímetro do Experimento ATLAS” XLI Encontro Nacional de Física de Partículas e Campos, 2021.

O experimento ATLAS utiliza o algoritmo *NeuralRinger* na etapa rápida do segundo nível de *Trigger*. Este algoritmo compacta a informação do sistema de calorimetria através da construção de anéis concêntricos ao redor da célula mais energética do chuveiro. Estes anéis são usados como entradas em uma *ensemble* de redes neurais especialistas onde cada uma das redes neurais atua em uma região de η e de E_T atuando no intervalo de $0 < \eta < 2,5$. A região *Forward* $\eta > 2,5$ é subdividida em três partes, o EMEC (*Electromagnetic End-Cap*), o *crack* e o FCAL (*Forward Calorimeter*). Não existe informação de traços e nem seleção para o *Trigger* nesta região. Dito isto, este trabalho busca estender o *NeuralRinger* para a região EMEC através de uma emulação das condições desta região, isto permitirá investigar a produção de *Drell-Yan*, aumentar o espaço de fase e o número de medidas relacionados ao Modelo Padrão de Partículas. Este trabalho utilizou dados coletados em 2017 provenientes do decaimento do bóson Z em um par elétron-pósitron para $E_T > 15$ GeV e $2,37 < \eta < 2,47$. Para emular o comportamento da região *Forward* foram removidos os anéis oriundos das camadas *PreSampler* e EM3. Os 84 anéis restantes foram utilizados como entradas em três modelos de aprendizado de máquina: um modelo MLP (*Multi Layer Perceptron*), um modelo convolucional mais complexo e um outro modelo convolucional desenvolvido para a região central do detector. O treinamento foi supervisionado baseando-se na

etiquetagem *offline* seguindo o critério de pureza *Medium*. O *K-fold* estratificado foi utilizado para avaliar a incerteza estatística associada aos modelos. Os resultados obtidos mostraram que foi possível manter a mesma taxa de detecção e o falso alarme foi reduzido substancialmente para todos os modelos testados, comparando com a referência para a região central do detector (*CutBased*). As próximas etapas incluem o estudo qualitativo dos modelos já treinados e a validação dos mesmos com os dados coletados em 2018.

2. Isabella S. Ferreira.; Eduardo Aguiar; Victor Assis; Micael V. de Araújo; Hans P. Beck; Márcia Begalli; Augusto S. Cerqueira; Paulo C. M. A. Farias; Victor A. Ferraz; Jefferson Horácio; Pedro H. G. Lima; Fernando P. Marciano; Juan L. Marin; Natanael Moura Júnior; Bernardo S. M. Peralva; Lucas B. A. Nunes; João V. F. Pinto; Eduardo Santos; Meinrad Schefer; José M. de Seixas; Eduardo F. de Simas Filho; Edmar E. P. de Souza; Rafael R. Vianna. “The High Level Trigger for Electrons and Photons in the ATLAS Experiment: The NeuralRinger’s Strategy for Decision Making and Calibration in the Fast Step” XLV Reunião de Trabalho sobre Física Nuclear no Brasil (RTFNB) e o XLII Encontro Nacional de Física de Partículas e Campos (ENFPC), 2022, Natal-RN.

With the increasing luminosity of the LHC, an increase in the stacking effect in the systems responsible for detecting particles of the ATLAS experiment is expected. Currently, collisions are produced every 25 ns, producing about 60 TB/s of information. Thus, the need to reject already known events is increasingly latent, especially where a lot of information is produced. To deal with this high rate of event production, the ATLAS experiment relies on an event selection system (trigger), responsible for accepting events of interest. In particular, the trigger of electrons and photons plays an important role in the many findings of the ATLAS experiment. To ensure that problems in the trigger of electrons and photons can be detected, a framework was developed for the monitoring of calorimetry variables that describe the energy deposition profile, the interaction points of the particles in the calorimeter and decision variables of the hypothesis algorithms in the different stages of the trigger of electrons and photons. The online monitoring provides the histograms of the variables that describe the shower of particles in the control room of the experiment during data collection. The developed framework is in operation in the main analysis software of the experiment and has met the different demands presented by the different subgroups of the ATLAS experiment. The identification of electrons with energy greater than 15 GeV has been carried out, since 2017, by the NeuralRinger algorithm in the first stage of the trigger. Due to its

effectiveness, the algorithm was adapted for selection of electrons with energy lower than 15 GeV and also for photons. In both cases, preliminary studies showed a reduction in the acceptance of false candidates with collision data for low-energy electrons and simulated data for photons, emulating the ATLAS trigger. In parallel, the use of the NeuralRinger was also proposed for the forward region of the ATLAS experiment, between $2.5 < |\eta| < 3.2$, also reducing the false electron acceptance rate. Recently, the use of the NeuralRinger for the identification of highly collimated (boosted) electrons was evaluated. Therefore, the number of rings used was reduced, leading to an increase in the identification rate of these candidates, proving to be useful for the selection of isolated particles. Due to the fact that the *NeuralRinger* uses the energy information from the shower developed by the particle to generate the signatures, its use was evaluated in the energy calibration problem, through the use of binary decision trees. An alternative version of the signatures, called asymmetric, is also evaluated in order to capture the asymmetries present in electromagnetic showers. Preliminary results show that there is a decrease in energy error after calibration measured with respect to the energy of the particle generated in simulated events.