



COPPE/UFRJ

SISTEMA *ONLINE* DE FILTRAGEM EM UM AMBIENTE COM ALTA TAXA
DE EVENTOS E FINA GRANULARIDADE

Rodrigo Coura Torres

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

Orientador: José Manoel de Seixas

Rio de Janeiro

Março de 2010

SISTEMA *ONLINE* DE FILTRAGEM EM UM AMBIENTE COM ALTA TAXA
DE EVENTOS E FINA GRANULARIDADE

Rodrigo Coura Torres

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

Examinada por:

Prof. José Manoel de Seixas, D.Sc.

Prof. Luiz Pereira Calôba, Dr.Ing.

Prof. Marcello Luiz Rodrigues de Campos, Ph.D.

Prof. Mariane Rembold Petraglia, Ph.D.

Prof. Márcio Portes de Albuquerque, D.Sc.

Prof. Charles Casimiro Cavalcante, D.Sc.

RIO DE JANEIRO, RJ – BRASIL

MARÇO DE 2010

Torres, Rodrigo Coura

Sistema *Online* de Filtragem em um Ambiente com Alta Taxa de Eventos e Fina Granularidade/Rodrigo Coura Torres. – Rio de Janeiro: UFRJ/COPPE, 2010.

XXVII, 242 p.: il.; 29, 7cm.

Orientador: José Manoel de Seixas

Tese (doutorado) – UFRJ/COPPE/Programa de Engenharia Elétrica, 2010.

Referências Bibliográficas: p. 209 – 219.

1. Filtragem *online*. 2. Física de altas energias. 3. Processamento veloz. 4. Extração de características. 5. Reconhecimento de padrões. I. Seixas, José Manoel de. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Elétrica. III. Título.

*À Deus, causa suprema de todas
as coisas. À minha amada
família, por todo o amor
incondicional dedicado a mim.*

Agradecimentos

- A Deus, pela saúde e disposição que me permitiram a realização deste trabalho.
- Aos meus pais, Osvani e João Carlos, que com seu amor incondicional, permitiram que me tornasse o homem que sou hoje.
- À minha irmã Yasmine, por sempre me apoiar e ser um pilar de apoio nos momentos difíceis.
- À minha avó, Olinda, por seu carinho e sabedoria adquirida ao longo dos anos, e ao meu avô Oswaldo, que infelizmente não se encontra mais fisicamente entre nós, mas que tenho certeza que está sempre ao meu lado.
- À minha namorada, Mariana, por sempre me apoiar, e por ficar me fazendo companhia por telefone, enquanto eu voltava para casa sozinho, de madrugada, do Fundão.
- Aos meus amigos, que sempre estavam dispostos a me ajudar nos momentos de dificuldade.
- Ao meu orientador, José Manoel de Seixas, por toda ajuda, indispensável na elaboração deste trabalho.
- Ao meu grande amigo, Denis Oliveira Damazio, por toda a ajuda com a análise dos dados, e por batalhar incessantemente ao nosso lado para ver este projeto inserido oficialmente no sistema de filtragem do ATLAS.
- Ao meus orientados, Dhiana Deva e Werner Freund, e ao semiorientado Danilo Enoque, pelo esforço e ajuda durante as pesquisas.
- A todos os amigos e colegas do CERN, que me acolheram tão bem, mesmo eu estando tão longe de casa.

- Aos funcionários e amigos do LPS, pela companhia sempre agradável durante a elaboração deste trabalho.
- Às atendentes do restaurante “Burguesão”, que com suas doses maciças de cafeína, contribuíram de maneira crucial para a conclusão deste trabalho.

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

SISTEMA *ONLINE* DE FILTRAGEM EM UM AMBIENTE COM ALTA TAXA DE EVENTOS E FINA GRANULARIDADE

Rodrigo Coura Torres

Março/2010

Orientador: José Manoel de Seixas

Programa: Engenharia Elétrica

O experimento ATLAS no CERN, Suíça, contará com um Sistema de Filtragem que deverá separar a Física ordinária dos eventos que possam representar decaimentos dos raros canais de interesse produzidos pelo LHC. O segundo nível deste sistema de filtragem constitui-se de cerca de 500 computadores ligados em rede, processando cada evento aprovado pelo primeiro nível em, na média, 40 milissegundos. Neste nível, opera um conjunto de algoritmos descritos em *software* que executa a seleção de eventos. Dentre estes, algoritmos de detecção de elétrons tem papel fundamental. Neste trabalho, apresentam-se algoritmos de discriminação mais eficientes baseados em redes neurais artificiais e um sistema de compactação de dados que se beneficia do perfil de deposição energético destas partículas em calorímetros. Técnicas de processamento estocástico de sinais são adotadas para isolar a informação relevante à classificação, proporcionando o desenvolvimento de classificadores mais simples. Os melhores resultados obtiveram, para uma mesma probabilidade de detecção, um falso alarme $\sim 65\%$ inferior ao obtido pelo algoritmo de referência do ATLAS para separação elétron / jato no segundo nível. A implementação *online* do algoritmo proposto mostrou que a solução desenvolvida atende aos restritos requisitos de tempo do segundo nível de filtragem.

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

ONLINE TRIGGERING SYSTEM FOR A HIGH EVENT RATE
ENVIRONMENT WITH FINE GRANULARITY

Rodrigo Coura Torres

March/2010

Advisor: José Manoel de Seixas

Department: Electrical Engineering

The ATLAS experiment at CERN, Switzerland, will count on a triggering system that separates the ordinary physics from the one representing decays of the rare physics channels. The second level of such a trigger system is composed by 500 computers connected by commodity networks, processing each event approved by the first-level trigger in 40 milliseconds, in average. A set of algorithms described via software will operate in this filtering level. Among them, electron detection systems play a fundamental role to the data acquisition since the existence of these particles can represent interesting physics. In this work, we present more efficient discrimination algorithms based on artificial neural networks and a compaction system which benefits from the energy deposit profiles of these particles in calorimeters. Statistical signal processing techniques are employed for isolating the discriminative information, allowing the development of simpler classifiers. The best obtained results provided, for the same detection efficiency, a false alarm $\sim 65\%$ lower than T2Calo, which is the base algorithm for electron / jet separation at level 2. The online implementation of the proposed system showed that the provided solution fulfills the stringent time requirements imposed by the second-level trigger.

Sumário

Lista de Figuras	xiii
Lista de Tabelas	xxi
Lista de Símbolos	xxiii
Lista de Abreviaturas	xxiv
1 Introdução	1
1.1 Motivação	2
1.2 Objetivo	5
1.3 Organização do Trabalho	9
2 Física de Altas Energias e o Projeto LHC	10
2.1 O Modelo Padrão	11
2.1.1 Partículas Materiais	11
2.1.2 Partículas Transportadoras de Força	12
2.1.3 Estendendo o Modelo Padrão	12
2.2 O Projeto LHC (<i>Large Hadron Collider</i>)	14
2.3 O Detetor ATLAS (<i>A Toroidal LHC Apparatus</i>)	18
3 Introdução à Calorimetria	22
3.1 Interação de Partículas com o Calorímetro	23
3.1.1 Absorção de Partículas Eletromagnéticas	23
3.1.2 Absorção de Partículas Hadrônicas	25
3.2 Identificação de Partículas Baseada em Calorimetria	27
3.2.1 Identificação Baseada na Informação Longitudinal	28

3.2.2	Identificação Baseada na Informação Lateral	29
3.2.3	Detetores de Pré-Irradiadores (<i>Pre-Showers</i>)	30
3.3	Sistemas de Calorimetria Utilizados em Colisionadores de Partículas	32
3.3.1	CMS	32
3.3.2	ZEUS	34
3.3.3	ATLAS	36
4	Sistemas de Filtragem	46
4.1	Sistemas de Filtragem <i>Online</i>	48
4.1.1	Sistemas de Filtragem em <i>Hardware</i>	49
4.1.2	Sistemas de Filtragem de Alto Nível	51
4.2	Sistemas de Filtragem <i>Offline</i>	54
5	Sistema de Filtragem do ATLAS	57
5.1	Primeiro Nível de <i>Trigger</i>	58
5.2	O Sistema de Filtragem de Alto Nível	60
5.2.1	Aquisição e Controle de Dados (<i>Data Aquisition and Control</i> - <i>DAQ</i>)	63
5.2.2	Unidades de Processamento	67
5.2.3	Comunicação entre os Módulos do Sistema de Filtragem	70
5.2.4	Athena	71
5.3	Formatação dos Dados	76
5.4	Identificação de Elétrons Baseada em Calorimetria	77
5.4.1	Primeiro Nível de Filtragem	77
5.4.2	Segundo Nível de Filtragem	79
6	Gerenciamento Automático do Sistema de Filtragem do ATLAS	84
6.1	O Servidor de Base de Dados	85
6.2	O <i>PartitionMaker</i>	89
6.3	Execução Automática do Sistema de Filtragem	96
7	Caracterização dos Dados Simulados e Anelamento para a Calorimetria	100
7.1	Geração dos Eventos	100

7.1.1	Interação com o Sistema de Calorimetria	101
7.1.2	Filtragem pelo Primeiro Nível	106
7.2	Pré-Processamento por Anéis Topológicos	109
7.2.1	Características Gerais	111
7.2.2	Robustez à Extrapolação em ϕ (ϕ <i>Wrap-Around</i>)	113
7.2.3	Correlação Linear entre Anéis	114
7.2.4	Correlação Não Linear	120
7.2.5	Normalização dos Anéis	121
7.2.6	Influência do Cintilador	128
7.3	Classificadores Neurais	131
7.3.1	Especificação da Topologia	132
7.3.2	Especificação do Treinamento	132
7.3.3	Análise da Flutuação Estatística	135
7.3.4	Apresentação das Eficiências de Classificação	136
8	Resultados com Dados de Simulação	137
8.1	Abordagens para a Extração de Características	138
8.2	Análise por Componentes Principais (PCA)	139
8.3	Análise por Componentes Principais de Discriminação	146
8.4	Análise de Componentes Independentes	152
8.4.1	Análise sem Compactação	153
8.4.2	Compactação por PCA	154
8.4.3	Compactação por PCD	158
8.5	Relevância dos Componentes	159
8.6	Resultados com Classificadores Lineares	170
8.7	Eficiência Computacional dos Métodos	177
8.8	Vantagens da Abordagem Segmentada	180
8.9	Vantagens do Pré-Processamento Não-Linear	181
9	Resultados com Dados Experimentais	182
9.1	Validação com Raios Cósmicos	183
9.1.1	Característica dos Eventos	183
9.1.2	Eficiência do Sistema de Classificação Proposto	186

9.2	Resultados com Dados de Colisão	190
9.3	Implementação no Athena	192
9.3.1	Algoritmo de Anelamento	194
9.3.2	Teste de Hipóteses	196
9.3.3	Serialização	196
9.3.4	Análise de Tempo do Algoritmo	198
10	Conclusões e Perspectivas	203
10.1	Perspectivas	207
	Referências Bibliográficas	209
A	Pré-Processamento Estocástico de Sinais	220
A.1	Análise de Componentes Principais	220
A.1.1	Branqueamento	221
A.2	Componentes Principais de Discriminação	222
A.2.1	Componentes Principais Ortogonais de Discriminação	224
A.3	Análise de Componentes Independentes	225
A.3.1	Independência Estatística	226
A.3.2	Algoritmos de Extração de Componentes Independentes	229
B	Sistema de Coordenadas do ATLAS	233
C	Lista de Publicações	236
C.1	Capítulos de Livros	236
C.2	Artigos Publicados em Revista	237
C.3	Artigos Publicados em Anais de Congressos	239
C.4	Resumos Publicados em Anais de Congressos	241

Lista de Figuras

2.1	Modelo padrão de partículas elementares.	11
2.2	Vista aérea do LHC.	15
2.3	Diagrama ilustrativo do detetor ATLAS.	17
2.4	Seção transversal do detetor ATLAS.	19
2.5	Interação de diferentes partículas com os diversos módulos do detetor ATLAS.	20
3.1	Perfil lateral médio do chuveiro produzido por píons de 80 GeV.	26
3.2	Exemplo da distribuição da razão de energia depositada nas seções hadrônicas e eletromagnéticas de um sistema de calorimetria, para elétrons e píons de 80 GeV.	28
3.3	Exemplo da distribuição do R_p , para elétrons e píons de 80 GeV.	30
3.4	Exemplo de resposta de um detetor de <i>pre-shower</i> para elétrons e píons.	31
3.5	Subdetetores do CMS.	33
3.6	Visão longitudinal esquemática do detetor ZEUS.	35
3.7	Conjunto de calorímetros do detetor ATLAS.	37
3.8	Estrutura de segmentação para cada camada do calorímetro eletromagnético.	38
3.9	Exemplo da interação (simulação) de um elétron com 70 GeV de energia transversa com todas as 4 camadas do calorímetro eletromagnético do barril.	39
3.10	Visão longitudinal de um quadrante do calorímetro eletromagnético.	41
3.11	Distribuição das células para o barril e o barril estendido do calorímetro hadrônico.	43

3.12	Exemplo da interação de um jato com 50 GeV de energia transversa com todas as 3 camadas do calorímetro hadrônico do barril.	44
3.13	Ilustração das barras metálicas sendo inseridas nos tubos da calorímetro de Argônio líquido do calorímetro hadrônico.	45
4.1	Taxa de eventos esperada durante a operação nominal do LHC.	47
4.2	Visão geral da hierarquia de um sistema de filtragem.	49
5.1	Diagrama em blocos do sistema de filtragem.	58
5.2	Diagrama em blocos do sistema de filtragem de alto nível.	61
5.3	Diagrama dos submódulos do ROS.	63
5.4	Contexto do supervisor do segundo nível.	65
5.5	Fluxo de processamento para cada evento recebido do primeiro nível e que leva a uma decisão do segundo nível.	69
5.6	Diagrama de conexão das redes de dados do HLT.	70
5.7	Organização do Athena para a filtragem de alto nível do ATLAS.	75
5.8	Formato geral dos eventos propagados pelo sistema de filtragem de alto nível.	76
5.9	Torres de <i>trigger</i> utilizadas para a seleção de elétrons no L1 do ATLAS.	78
5.10	Distribuição das 4 variáveis de corte empregadas pelo T2Calo.	80
5.11	Percentual de redução no número de eventos após o corte em cada variável do T2Calo para elétrons (à esquerda) e para jatos (a direita).	81
5.12	Eficiência global do T2Calo, e a distribuição da eficiência em função de E_T , η e ϕ	83
6.1	Diagrama simplificado com o exemplo da organização dos atributos e relações entre os módulos do TDAQ.	86
6.2	Estrutura de controle hierárquico do sistema de filtragem.	88
6.3	Diagrama em blocos do <i>PartitionMaker</i>	91
6.4	Exemplo de fluxo de geração de uma partição.	93
6.5	Exemplo de geração de uma partição.	94
6.6	Exemplo do fluxo de processamento do sistema de execução automática do TDAQ.	97

7.1	Distribuição do momento transverso, η e ϕ dos eventos contidos nas simulações de Monte Carlo utilizadas.	101
7.2	Deposição de energia pelas camadas dos calorímetros EM e HAD para um elétron típico.	102
7.3	Deposição de energia pelas camadas dos calorímetros EM e HAD para um jato típico.	103
7.4	Distribuição da informação proveniente dos calorímetros para cada tipo de partícula.	104
7.5	Razão entre a deposição de energia na seção HAD e EM (em cima) e a distribuição, em η dos eventos com razão $E_{HAD}/E_{EM} > 10\%$ (embaixo).	105
7.6	Absorção de elétrons pelos calorímetros eletromagnéticos e hadrônicos para o conjunto de elétrons.	107
7.7	Variáveis de corte calculadas pelo L1 para a identificação de elétrons.	109
7.8	Distribuição do número de células de calorimetria por RoI para elétrons (em cima) e jatos (embaixo).	110
7.9	Exemplo da organização das células em anéis concêntricos para diferentes camadas dos calorímetros.	111
7.10	Característica geral dos eventos após o anelamento.	113
7.11	Distribuição dos anéis por energia para o corte e10 para elétrons (em cima) e jatos (embaixo).	114
7.12	Energia depositada em cada grupo de anéis quando ao incluir-se a energia dos cintiladores (coluna da esquerda) e ao excluir-se os cintiladores (coluna da direita).	115
7.13	Distribuição, em η , das células pertencentes às 3 camadas de cintiladores posicionadas na fenda existente entre o barril e a tampa do calorímetro eletromagnético.	115
7.14	Perfil dos anéis após a aplicação do corte com isolamento pelo L1. . .	116
7.15	Distribuição dos anéis por energia para o corte e15i para elétrons (em cima) e jatos (embaixo).	116
7.16	Distribuição em ϕ dos casos de RoI com extrapolação da coordenada ϕ na versão original (em cima), e após a correção (embaixo).	117

7.17	Coeficiente de correlação linear entre os 100 anéis para os cortes e10 e e15i.	118
7.18	Regiões, em η , de ocorrência de anéis nulos na EM1 (em cima), e a distribuição destes anéis nulos para um evento típico (embaixo).	119
7.19	Informação mútua (normalizada) entre os 100 anéis para os cortes e10 e e15i.	121
7.20	Eficiência de classificação para os diversos tipos de normalização em energia considerado para os anéis.	125
7.21	Variação da probabilidade de detecção (em cima) e do falso alarme (embaixo) em função da energia transversa do evento.	126
7.22	Eficiências obtidas com a normalização sequencial, ao variar-se seus limiares E_{stop} e E_{thres}	127
7.23	Eficiência obtida com discriminadores neurais treinados com anéis produzidos com e sem a informação dos cintiladores.	129
7.24	Distribuição bidimensional das saídas das redes neurais treinadas para anéis com e sem a informação dos cintiladores.	130
7.25	Probabilidade de desacordo, em função de E_T (à esquerda) e η (à direita), para o conjunto de elétrons (em cima) e jatos (embaixo), dos classificadores alimentados com anéis com e sem a informação dos cintiladores.	131
7.26	Variação do SP de teste de acordo com o tamanho da batelada.	133
7.27	Variação do SP de teste de acordo com o número de épocas de treinamento.	134
8.1	Fluxo de processamento para ambas abordagens.	138
8.2	Curva de carga obtida após a extração dos componentes principais (abordagem segmentada e não segmentada).	139
8.3	Quantidade (em valores percentuais) de variância retida, para a EM2, pelos anéis, e por seus componentes principais (em cima) e a distribuição bidimensional entre os 2 primeiros anéis e os 2 primeiros componentes principais (embaixo). As linhas contínuas representam a melhor aproximação linear para os dados.	140

8.4	Correlação bidimensional, para a HD3, entre os anéis em sua base canônica e projetados na base de componentes principais. As linhas contínuas representam a melhor aproximação linear para os dados. . .	141
8.5	Resultados de classificação neural obtidos para diferentes percentuais de cortes em energia via PCA.	143
8.6	Distribuição da saída do classificador alimentado com os componentes principais segmentados compactados à 99% da energia do evento. A linha pontilhada representa o limiar de corte que provê o máximo SP.	144
8.7	Variação da eficiência (em cima) e do falso alarme (embaixo) para o classificador alimentado com os componentes principais segmentados compactados a 99%, em função de E_T e η	145
8.8	Evolução do SP de acordo com o número de componentes principais de discriminação extraídos do caso segmentado e não segmentado. . .	146
8.9	Evolução do SP de acordo com o número de componentes principais ortogonais de discriminação extraídos do caso segmentado e não segmentado.	148
8.10	Eficiência de discriminação obtida com componentes principais de discriminação.	150
8.11	Projeção no primeiro PCA (à direita) e no primeiro PCD (à esquerda). A linha pontilhada representa o limiar de corte que proporciona o melhor produto SP.	150
8.12	Variação da eficiência (em cima) e do falso alarme (embaixo) para o classificador alimentado com os componentes principais de discriminação, em função de E_T e η	151
8.13	Exemplos de vetores da base de componentes independentes extraídos, de maneira não segmentada, a partir dos dados sem compactação.	153
8.14	Resultados de classificação neural obtidos para a ICA baseada na dimensão total dos anéis.	154
8.15	Resultados de classificação neural obtidos para a ICA baseada na compactação em energia dos anéis via PCA.	155

8.16	Comparação das eficiências de classificação obtidas através da projeção nos componentes principais e independentes.	156
8.17	Variação da eficiência (em cima) e do falso alarme (embaixo) para o classificador alimentado com os componentes independentes extraídos após a projeção na base de componentes principais, compactada à 99% da informação.	157
8.18	Resultados de classificação neural obtidos para a ICA baseada na compactação dos anéis via PCD.	158
8.19	Relevância de cada anel topológico para o discriminador neural. . . .	161
8.20	Relevância dos componentes principais para o discriminador neural. .	162
8.21	Relevância dos componentes principais de discriminação para o discriminador neural. Abordagem não segmentada (em cima) e segmentada (embaixo).	163
8.22	Relevância dos componentes independentes para o discriminador neural.	165
8.23	Relevância dos componentes independentes selecionados por componentes principais de discriminação. Não segmentada (em cima) e segmentada (embaixo)	166
8.24	Resultados de classificação para as entradas mais relevantes obtidas com anéis puros.	167
8.25	Resultados de classificação para as entradas mais relevantes obtidas com os pré-processamentos com compactação por PCA.	168
8.26	Resultados de classificação para as entradas mais relevantes obtidas com ICA compactada por PCA.	169
8.27	Resultados de classificação para as entradas mais relevantes obtidas com os pré-processamentos com compactação por PCD.	171
8.28	Comparação entre rede neural e discriminante de Fisher para anéis puros.	172
8.29	Comparação entre rede neural e discriminante de Fisher para casos com compactação via PCA.	173
8.30	Comparação entre rede neural e discriminante de Fisher para casos com compactação via PCD.	175
9.1	Distribuição em E_T , η e ϕ para os raios cósmicos.	184

9.2	Distribuição dos eventos em função de η e ϕ (à esquerda), e em função de η e E_T (à direita).	185
9.3	Distribuição dos eventos em função de η e ϕ (à esquerda), e em função de η e E_T (à direita).	186
9.4	Exemplo de um evento fantasma na região centrada em $(\eta;\phi) = (-0,3; 1,6)$	187
9.5	Exemplo de um evento fantasma na região centrada em $(\eta;\phi) = (1,4; -1,2)$	187
9.6	Saída do classificador neural para raios cósmicos. A linha tracejada representa o limiar de corte.	188
9.7	Formato médio dos cósmicos aprovados (em cima) e rejeitados (em baixo). O formato médio de elétrons e jatos também é apresentado como referência.	189
9.8	Evolução na redução do número de eventos a cada corte aplicado pelo T2Calo.	189
9.9	Probabilidades de rejeição em função de E_T (em cima), η (no centro) e ϕ (embaixo) entre o classificador neural e o T2Calo.	190
9.10	Visualização da interação com o ATLAS dos eventos provenientes de colisões do LHC.	191
9.11	Eficiência de detecção de elétrons para o sistema proposto e o T2Calo.	192
9.12	Fluxo de informação pelos pacotes empregados para a filtragem de eventos no Athena.	193
9.13	Percentual de tempo em cada etapa de processamento do T2Calo (à esquerda), e acrescido das etapas de processamento do sistema proposto (à direita).	198
A.1	Exemplo onde o componente principal mais energético não fornece nenhuma informação útil para a distinção entre classes.	223
A.2	Exemplo de como a PCD fornece direções úteis à distinção entre classes.	223
A.3	Esquema de extração dos componentes principais de discriminação.	224
A.4	Esquema de extração dos componentes principais ortogonais de discriminação.	225

B.1	Sistema cartesiano de coordenadas do ATLAS.	234
B.2	O sistema de coordenadas do ATLAS.	234
B.3	Visualização do problema de extrapolação da coordenada ϕ (<i>wrap-around</i>).	235

Lista de Tabelas

3.1	Granularidade de cada camada do calorímetro eletromagnético.	40
3.2	Granularidade de cada camada do calorímetro hadrônico.	43
4.1	Luminosidade, frequência de colisões e volume de informação produzido para os principais colisionadores da atualidade.	48
5.1	Exemplo de frequência de observação de eventos no primeiro nível, com luminosidade máxima ($L = 10^{34} \text{ cm}^{-2}\text{s}^{-1}$)	59
5.2	Quantidade de processadores necessários para cada módulo do sistema de filtragem de alto nível do ATLAS.	62
7.1	Cortes considerados para o L1 para as duas assinaturas abordadas. . .	108
7.2	Número de RoI obtidas para cada padrão após filtragem pelo L1, para as assinaturas abordadas (veja a Seção 5.4.1 para detalhes).	108
7.3	Organização dos anéis para cada conjunto.	112
7.4	Valores utilizados para cada parâmetro do treinamento neural.	135
8.1	Número de componentes retidos para cada critério de seleção.	143
8.2	Comparação entre o SP obtido utilizando-se informação de segmentos isolados.	147
8.3	Número de componentes principais de discriminação selecionados. . .	149
8.4	Resumo dos resultados obtidos para cada abordagem utilizando classificador neural. O melhor resultado encontrado está em negrito.	160
8.5	Resumo dos resultados obtidos para cada abordagem utilizando redes neurais alimentadas com as entradas mais relevantes. O melhor resultado encontrado está em negrito.	170

8.6	Resumo dos resultados obtidos para cada abordagem utilizando discriminador de Fisher. O melhor resultado encontrado está em negrito.	176
8.7	Número de operações de multiplicação e acumulação (MAC).	179
9.1	Tempos para a criação dos anéis.	195
9.2	Tempos de Execução do Algoritmo de Classificação (Rede $100 \times 18 \times 1$).	196
9.3	Tempo gasto em cada etapa de processamento.	199
9.4	Tempos (em microssegundos) para a criação dos anéis de cada camada.	201

Lista de Símbolos

E_T	Energia transversa, p. 32
η	Coordenada do calorímetro do ATLAS (pseudorapidez), p. 233
ϕ	Coordenada do calorímetro do ATLAS, p. 233
p_T	Momento transversa, p. 58

Lista de Abreviaturas

ASIC	<i>Application Specific Integrated Circuit</i> , p. 49
ATLAS	<i>A Toroidal LHC Apparatus</i> , p. 18
CERN	Centro Europeu de Pesquisa Nuclear, p. 3
CTRLN	<i>Control Data Network</i> , p. 70
DAQ	<i>Data Aquisition and Control</i> , p. 63
DFM	<i>Dataflow Manager</i> , p. 66
DSP	<i>Digital Signal Processors</i> , p. 49
EBN	<i>Event Builder Data Network</i> , p. 70
EFD	<i>Event Filter Dataflow</i> , p. 69
EFN	<i>Event Filter Data Network</i> , p. 70
EFP	<i>Event Filter Processor</i> , p. 69
EF	<i>Event Filter</i> , p. 60
EM1	1 ^a camada eletromagnética, p. 112
EM2	2 ^a camada eletromagnética, p. 112
EM3	3 ^a camada eletromagnética, p. 112
EMBARREL1	1 ^a camada do barril do calorímetro eletromagnético, p. 112
EMBARREL2	2 ^a camada do barril do calorímetro eletromagnético, p. 112
EMBARREL3	3 ^a camada do barril do calorímetro eletromagnético, p. 112

EMENDCAP1	1 ^a camada da tampa do calorímetro eletromagnético, p. 112
EMENDCAP2	2 ^a camada da tampa do calorímetro eletromagnético, p. 112
EMENDCAP3	3 ^a camada da tampa do calorímetro eletromagnético, p. 112
EM	Eletromagnético, p. 112
ESS	<i>Events Selection Software</i> , p. 68
FPGA	<i>Field-Programmable Gate Array</i> , p. 4
HADENCAP0	1 ^a camada da tampa do calorímetro hadrônico, p. 112
HADENCAP1	2 ^a camada da tampa do calorímetro hadrônico, p. 112
HADENCAP2	3 ^a camada da tampa do calorímetro hadrônico, p. 112
HADENCAP3	4 ^a camada da tampa do calorímetro hadrônico, p. 112
HAD	Hadrônico, p. 112
HD1	1 ^a camada hadrônica, p. 112
HD2	2 ^a camada hadrônica, p. 112
HD3	3 ^a camada hadrônica, p. 112
HLT	<i>High Level Trigger</i> , p. 60
ICA	Análise de Componentes Independentes, p. 225
L1	Primeiro nível de filtragem do ATLAS, p. 58
L2N	<i>Level 2 Data Network</i> , p. 70
L2PU	<i>Level 2 Processing Unit</i> , p. 68
L2P	<i>Level 2 Processor</i> , p. 67
L2RH	<i>Level 2 Result Handler</i> , p. 66
L2SV	<i>Level 2 Supervisor</i> , p. 65
L2	Segundo nível de filtragem, p. 60

LHC	<i>Large Hadron Collider</i> , p. 14
LUT	<i>Lookup Table</i> , p. 51
MAC	Multiplicações e acumulações, p. 177
PCA	Análise de Componentes Principais, p. 220
PCD	Análise de Componentes Principais de Discriminação, p. 222
PSBARREL	Barril do <i>pre-sampler</i> , p. 112
PSC	<i>PESA Steering Controller</i> , p. 68
PSENDCAP	Tampa do <i>pre-sampler</i> , p. 112
PS	<i>Pre-sampler</i> , p. 112
PT	<i>Processing Task</i> , p. 69
RICA	Análise de Componentes Independentes Relevantes, p. 137
ROB	<i>Read-Out Buffer</i> , p. 63
ROS	<i>Read-Out System</i> , p. 63
RPC	<i>Resistive Plates Chambers</i> , p. 59
RoIB	<i>RoI Builder</i> , p. 64
RoI	<i>Region of Interest</i> , p. 60
SFI	<i>Subfarm Input</i> , p. 66
SFO	<i>Subfarm Output</i> , p. 67
SIMD	<i>Single Instruction on Multiple Data Stream</i> , p. 51
TDAQ	<i>Trigger and Data Aquisition</i> , p. 62
TILEBARREL0	1 ^a camada do barril do calorímetro hadrônico, p. 112
TILEBARREL1	2 ^a camada do barril do calorímetro hadrônico, p. 112
TILEBARREL2	3 ^a camada do barril do calorímetro hadrônico, p. 112

TILEEXTB0	1 ^a camada do barril estendido do calorímetro hadrônico, p. 112
TILEEXTB1	2 ^a camada do barril estendido do calorímetro hadrônico, p. 112
TILEEXTB2	3 ^a camada do barril estendido do calorímetro hadrônico, p. 112
TILEGAPSCI0	1 ^a camada do cintilador colocado no <i>gap</i> , p. 112
TILEGAPSCI1	2 ^a camada do cintilador colocado no <i>gap</i> , p. 112
TILEGAPSCI2	3 ^a camada do cintilador colocado no <i>gap</i> , p. 112

Capítulo 1

Introdução

Sistemas de filtragem de dados são ferramentas empregadas em diversas áreas, com o objetivo de separar um conjunto de sinais de interesse daqueles que não agreguem informação relevante ao problema. Atualmente, devido à complexidade de certos problemas, tem-se que o volume de informação a ser analisada torna-se bastante grande, de forma que a dimensão do espaço original de dados de entrada tende a ser consideravelmente elevada, dificultando o processo de análise dos mesmos. Adicionalmente, como a taxa de eventos pode ser muito elevada, a velocidade com a qual a filtragem é realizada deve ser capaz de atender a taxa com a qual se espera que esses resultados sejam gerados, o que é especialmente importante quando se planeja que o sistema de filtragem opere de maneira *online*. Por último, pode-se destacar situações onde, além do volume de dados ser muito grande, o evento de interesse seja bastante raro, devendo o sistema ser capaz de identificar estes raros eventos num volume muito maior de eventos sem interesse. Assim sendo, desenvolver métodos otimizados de filtragem passa a ser um desafio. Em geral, é desejável que estes sistemas de filtragem apresentem as seguintes características:

- Alta eficiência na identificação dos eventos de interesse, aliada a uma baixa incidência de falso alarme.
- Implementação (*software e/ou hardware*) simplificada.
- Flexibilidade de alteração do sistema desenvolvido, de forma a atender possíveis atualizações e requisitos futuros.
- Velocidade de execução compatível com os requisitos de tempo do projeto.

- Robustez, de forma que o sistema desenvolvido mantenha suas características funcionais ao longo do tempo de sua utilização.
- Facilidade de integração com outros módulos que com ele se comuniquem.

Para lidar com o problema da alta dimensão dos eventos, pode-se adotar técnicas que visam extrair a informação realmente relevante do processo abordado, de forma a se descartar a informação inútil ao objetivo do experimento e, assim, reduzir a dimensão dos eventos, sem, no entanto, desprezar a parte interessante dos mesmos. Para tal, é possível utilizar métodos baseados no conhecimento especialista sobre o problema, normalmente mais simples, ou métodos baseados em processamento estocástico, que, baseados na estatística do processo, conseguem, frequentemente, reter mais eficientemente a informação sobre o processo abordado.

O processamento estatístico pode ser ainda combinado ao conhecimento especialista que se possui sobre o problema de classificação, resultando em uma abordagem bastante poderosa. Como, na maioria das vezes, o problema a ser resolvido é não linear, a adoção de técnicas estocásticas ganha ainda mais força. Através da utilização de algoritmos baseados em estatísticas de ordem superior e de técnicas não lineares (redes neurais, por exemplo), guiadas pelo conhecimento especialista a respeito do problema em mãos, torna-se possível lidar eficientemente com a natureza complexa da informação, de forma a executar otimadamente o processo de discriminação, com algoritmos rápidos e com ótimos índices de classificação.

1.1 Motivação

A física experimental de altas energias é um dos ramos da ciência que mais exige de sistemas de processamento. Isto ocorre, uma vez que a física experimental visa confirmar, experimentalmente, teorias propostas pela física teórica. Entretanto, tem-se que preencher a distância que existe entre o desenvolvimento de uma nova teoria e a conseqüente validação da mesma através de experimentos, uma vez que tais experimentos normalmente exigem tecnologias ainda não disponíveis, ou altamente elaboradas. Neste aspecto, sistemas de filtragem são bastante utilizados na física experimental. Requisitos severos para um sistema de filtragem são tipicamente encontrados na filtragem de eventos obtidos em experimentos com colisionadores de

partículas, uma vez que o número de eventos gerados tende a ser bastante elevado nestes experimentos.

Atualmente, no CERN (Centro Europeu de Pesquisa Nuclear), encontra-se, em início de operação, o projeto LHC (*Large Hadron Collider*). O LHC é um novo acelerador capaz de atingir níveis de energia nunca antes alcançados, devendo colidir pacotes com um número elevado de prótons com 14 TeV de energia em seu centro de massa. A detecção dos eventos gerados através das colisões será realizada, entre outros detetores, pelo detetor ATLAS (*A Toroidal LHC Apparatus*), que contém os seguintes detetores:

- Detetor de traços para a determinação da trajetória de partículas.
- Calorímetro Eletromagnético para a análise da deposição energética de partículas eletromagnéticas.
- Calorímetro Hadrônico para a análise da deposição energética de partículas hadrônicas.
- Detetor de Múons para a identificação e determinação da trajetória de múons.

No ATLAS, o sistema de calorimetria tem um papel fundamental. Os calorímetros, os quais medem a energia das partículas incidentes, são bastante rápidos (respostas geradas em algumas dezenas de nanossegundos) e possuem fina granularidade (alta resolução). As partículas, ao interagirem com o sistema de calorimetria, depositam nele a sua energia (total ou parcial). Dependendo do perfil de deposição de energia, pode-se identificar a classe da partícula incidente. No ATLAS, o sistema de calorimetria está dividido em 7 camadas concêntricas, onde as 4 primeiras constituem o calorímetro eletromagnético, e 3 últimas o calorímetro hadrônico.

Os canais físicos de interesse sendo estudados no ATLAS são muito raros, podendo ser observados algumas poucas vezes ao longo de vários dias de colisão, nas condições nominais de operação do ATLAS. Entretanto, a frequência de eventos gerados durante o processo de colisão no LHC é da ordem de 40 MHz, sendo que cada evento produz, aproximadamente, 1,5 MByte de informação. Deste modo, o fluxo de dados será da ordem de 60 TBytes por segundo, impossibilitando o armazenamento completo desses eventos para análise *offline*. Assim, um sistema de filtragem *online*

torna-se indispensável para o experimento. O sistema de filtragem deve identificar os raros padrões de decaimento que representam a física de interesse para poder isolá-los da massa de eventos com física ordinária, produzida pelas interações mal sucedidas (interações que produzem canais físicos irrelevantes ao experimento, e que, portanto, significam ruído de fundo para o ATLAS).

O sistema de filtragem desenvolvido é composto por três níveis sequenciais de análise:

1. O primeiro nível do sistema de filtragem recebe todos os eventos gerados nas colisões e, devido à alta taxa de eventos gerados, é implementado em *hardware* de baixa programabilidade (FPGA). Através da diminuição da granularidade do detetor, atinge-se a taxa elevada de processamento que é necessária. Como resultado, reduz-se, neste nível, a taxa de eventos, dos 40 MHz originais, para aproximadamente 75 kHz (podendo ser expandida, no futuro, para 100 kHz). Sua informação é baseada em calorimetria e detetores rápidos de múons.

O primeiro nível de *trigger* é responsável, também, por selecionar áreas onde há informação relevante, gerando uma região de interesse (RoI). Somente estas regiões (e não toda a área do detetor) é propagada para o segundo nível, de forma que se aumenta a banda passante do sistema.

2. O segundo nível analisa apenas os eventos que passaram pelas condições do primeiro nível, e será implementado em *software* de alto nível, utilizando uma rede de aproximadamente 500 processadores (cada um com 4 núcleos de processamento) conectados em rede. Este nível processa algoritmos de busca especializados nos diversos subdetetores do ATLAS, procurando encontrar elementos que representem canais (produtos) físicos de interesse. Após este nível, a taxa de eventos já estará reduzida a aproximadamente 2 kHz.
3. No terceiro nível, a análise será feita utilizando-se toda a informação recolhida para um evento. Exige pesado ambiente computacional (aproximadamente 1900 processadores). Espera-se, ao final desta fase, que a frequência de eventos esteja reduzida a aproximadamente 200 Hz. Ao final desta fase, os dados serão armazenados, em mídia permanente, para posterior análise *offline*.

1.2 Objetivo

Os eventos que chegam ao segundo nível de filtragem do ATLAS, por já terem passado pelo primeiro nível, apresentam características bem menos distintas para a discriminação, o que torna o processo de filtragem *online* mais complicado. Por outro lado, o segundo nível de filtragem, por se beneficiar de um tempo maior de processamento, pode explorar técnicas de filtragem mais complexas. Desta forma, neste trabalho aborda-se o processo de filtragem a ser realizado no segundo nível de *trigger*, utilizando o sistema de calorimetria do mesmo, de forma a reter os principais canais de interesse do experimento.

A identificação de eventos de interesse é realizada, principalmente, observando-se as partículas mais estáveis que foram produzidas pela decomposição de partículas instáveis, sendo estas, o alvo principal das pesquisas. Existem vários canais físicos de interesse gerados no processo de decaimento. Entretanto, este trabalho aborda os casos onde são produzidos elétrons no estado final, convertendo a identificação de elétrons numa tarefa primordial do segundo nível de filtragem. Por outro lado, jatos, que são partículas produzidas em grande quantidade durante colisões hadrônicas, por poderem apresentar um perfil de deposição de energia muito semelhante ao de elétrons, mascaram a assinatura destes, e estão, em geral, relacionados ao ruído de fundo do experimento. Por tal motivo, estes jatos devem ser descartados.

Cada evento (RoI) recebido pelo segundo nível de filtragem apresenta dimensão elevada (em média, 1.000 células por RoI). Além disso, os eventos estão imersos em ruído de fundo, às vezes provenientes de interações remanescentes de partículas que atingiram o detetor instantes antes do evento considerado (efeito de empilhamento), contribuindo para um ainda maior mascaramento da informação relevante do sinal a ser classificado. Este efeito de empilhamento ocorre quando se utiliza a luminosidade máxima dos feixes, o que é o modo de operação nominal previsto para o LHC. A alta luminosidade aumenta as chances de produção de eventos de interesse, ao custo de elevar, também, a quantidade de ruído de fundo produzido.

Os problemas relacionados ao projeto do segundo nível de filtragem (velocidade, dimensão e níveis de ruído elevados) tendem a tornar o processo de classificação de eventos uma tarefa bastante complexa. Desta maneira, neste trabalho, métodos de pré-processamento foram utilizados para reduzir a dimensão do espaço original

de dados através da retenção da informação realmente relevante ao processo de classificação. Foram estudados tanto métodos de pré-processamento baseados na informação topológica do sinal a ser classificado, bem como técnicas do processamento estatístico de ordem superior.

Para o pré-processamento topológico das RoI, um modelo baseado em soma em anéis concêntricos à célula quente de cada camada foi adotado, visto que já apresentou bons resultados em trabalhos anteriores. Estes anéis permitem, camada a camada, extrair de forma compacta a informação sobre o perfil de deposição de energia em cada camada, mantendo, ainda assim, a interpretação física do processo. Após o algoritmo de anelamento, um processo de normalização baseado na energia de cada evento foi empregado, de forma a reduzir a contribuição da energia no processo de classificação.

Neste trabalho, os anéis produzidos pelo pré-processamento topológico foram utilizados para o desenvolvimento de uma segunda etapa de pré-processamento, baseada na estatística do processo. Com este objetivo, foram exploradas técnicas para a decorrelação linear e não linear dos anéis, bem como técnicas não lineares que visam projetar a informação de entrada em uma base que maximize a distinção entre classes. Adicionalmente, a análise da relevância de cada componente para o processo de classificação foi estudada, visando determinar quais componentes poderiam ser eliminados para simplificar o desenvolvimento do classificador, sem impactar negativamente a eficiência de classificação.

Para a decorrelação não linear, este trabalho utilizou a análise de componentes independentes (ICA). Para se determinar o número ótimo de fontes independentes, compactações via componentes principais (PCA) e de discriminação (PCD) foram empregadas. Entretanto, para a seleção do número ótimo de fontes independentes para a classificação, a análise via componentes independentes relevantes (RICA) foi empregada. Esta técnica consiste em, inicialmente, empregar técnicas como PCA ou PCD para a compactação inicial da informação, visando a extração dos componentes independentes. Em seguida, a análise da relevância é empregada para se isolar as fontes independentes que contenham a informação realmente discriminante para o classificador.

Para explorar características inerentes de cada camada do sistema de calorime-

tria do ATLAS, o pré-processamento dos anéis foi realizado camada a camada, em uma abordagem segmentada. Ao final do processamento de cada camada, os componentes selecionados foram concatenados, formando um único evento a alimentar o discriminador. Por outro lado, a abordagem não segmentada (tratando todos os anéis como um único vetor de entrada) pode explorar relações existentes entre as camadas, resultando, normalmente, em um menor número de componentes selecionados para a classificação. Desta forma, a análise não segmentada também foi abordada neste trabalho.

Uma vez que se reduz a dimensão do evento e o mascaramento da informação relevante do mesmo, foram desenvolvidos, neste trabalho, classificadores mais simples, eficientes do ponto de vista de classificação, velozes e com baixo requerimento de memória, características fundamentais para a implementação do sistema em ambiente *online*.

Redes Neurais têm mostrado um desempenho muito bom em aplicações de reconhecimento de padrões. Para calorímetros, a identificação de partículas por métodos neurais tem sido tentada com bastante sucesso. Esta técnica torna-se bastante interessante, dado que é capaz de diferenciar padrões cujas diferenças são bastante sutis. Além disso, são classificadores bastante velozes, e como são desenvolvidos baseados na estatística do problema, tendem a generalizar muito bem a solução, podendo fornecer uma saída coerente mesmo quando um dado nunca antes visto é apresentado. Desta maneira, foi adotada uma rede neural como sistema de classificação dos eventos pré-processados pelas técnicas propostas neste trabalho. Entretanto, as técnicas de pré-processamento utilizadas podem evidenciar de tal forma a informação discriminante ao ponto de permitir que um modelo linear de classificação possa ser adotado, sem redução significativa na eficiência de classificação. Desta forma, este trabalho também estudou a viabilidade da utilização de discriminadores lineares para a etapa de classificação.

O sistema de classificação desenvolvido neste trabalho foi implementado no segundo nível de filtragem do ATLAS. Com esta implementação, análises mais precisas foram realizadas para garantir que o sistema desenvolvido atende os restritos requisitos de tempo do segundo nível de filtragem. Adicionalmente, os algoritmos desenvolvidos neste trabalho foram comparados com o algoritmo de referência para

a identificação de elétrons no segundo nível de filtragem do ATLAS, utilizando as ferramentas de análise da própria colaboração ATLAS.

Com a implementação dos algoritmos de discriminação elétron / jato no segundo nível de filtragem, dados de simulação de Monte Carlo de última geração foram adquiridos para as análises realizadas neste trabalho. Desta forma, as técnicas de processamento estocástico acima descritas foram adotadas sobre estes dados de simulação de última geração, visto que representam, até o momento, a imagem mais realista do ambiente operacional do LHC e do ATLAS, antes do início de suas atividades. Graças à esta implementação *online*, este trabalho também realizou análises do sistema proposto com dados experimentais oriundos de radiação cósmica, e de colisões realizadas a baixas energias.

O sistema de filtragem do ATLAS, além de ser um ambiente extremamente complexo, encontra-se em constante evolução. Melhorias na calibração dos detetores, desenvolvimento de simulações de Monte Carlo mais fidedignas, e novas versões dos muitos módulos que compõem este ambiente estão sempre sendo apresentados à colaboração. Incorporar tais evoluções requer a execução de um grande número de testes de validação. Adicionalmente, o trabalho desenvolvido precisa ser inserido neste complexo ambiente, passando, também, por este rigoroso processo de validação. Por fim, todo o dinamismo da colaboração do sistema de filtragem, aliado à quantidade de conhecimento necessário para a compreensão de toda a estrutura do sistema de filtragem, tornam bastante complicado para novos colaboradores se inserirem neste ambiente e, em curto espaço de tempo, apresentarem propostas de melhorias para o sistema de filtragem.

Neste aspecto, a automatização do gerenciamento do sistema de filtragem torna-se crucial para membros da colaboração dispostos a apresentarem novas propostas de melhorias para o sistema de filtragem, bem como para os testes de validação continuamente realizados neste sistema. Dado que o sistema de filtragem do ATLAS foi concebido para ser extremamente configurável, torna-se necessário, a cada teste, prover os parâmetros de configuração de todos os módulos (que podem chegar a milhares) envolvidos em um dado teste. Uma configuração mal feita pode resultar na interrupção do teste, desperdiçando recursos do projeto. Conseqüentemente, a correta configuração do sistema de filtragem possui um papel fundamental para

a realização eficiente de testes de melhorias e de novos algoritmos no sistema de filtragem do ATLAS.

Desta forma, para a validação do trabalho proposto no sistema de filtragem do ATLAS, métodos automatizados de configuração do sistema de filtragem do ATLAS foram desenvolvidos como parte deste trabalho. Visando estreitar os laços de colaboração entre a UFRJ e o projeto ATLAS, os mecanismos de automatização desenvolvidos, inicialmente destinados apenas ao segundo nível de filtragem, terminaram por englobar todo o sistema de filtragem de alto nível, gerando grande otimização no que tange a configuração dos módulos deste complexo ambiente.

1.3 Organização do Trabalho

Este documento está organizado da seguinte maneira: o Capítulo 2 apresenta uma breve introdução à física de altas energias, e descreve o LHC e o experimento ATLAS. O Capítulo 3 apresenta os fundamentos básicos da calorimetria moderna, apresentando ao final, além do calorímetro do ATLAS, alguns dos calorímetros atualmente empregados em pesquisas de altas energias. A seguir, o Capítulo 4 apresenta os fundamentos da filtragem de eventos em física experimental. Neste capítulo, também é feita a revisão da literatura em algoritmos de filtragem baseados em calorimetria. Já no Capítulo 5, é apresentado, com maiores detalhes, o sistema de filtragem do ATLAS. No Capítulo 6, são apresentados os mecanismos de automação desenvolvidos para o gerenciamento automático do sistema de filtragem, com foco no módulo de configuração desenvolvido neste trabalho. A análise dos dados de simulação empregados no desenvolvimento deste trabalho é apresentada no Capítulo 7. Após esta análise, são apresentados, no Capítulo 8, os resultados obtidos com as técnicas de processamento estocástico empregadas para a seleção de características relevantes à classificação elétron / jato. As técnicas desenvolvidas são validadas com dados experimentais no Capítulo 9, onde também será apresentada a implementação dos resultados deste trabalho no ambiente *online* do sistema de filtragem do ATLAS. As conclusões referentes a este trabalho são apresentadas, por sua vez, no Capítulo 10, junto com as perspectivas de pesquisas futuras.

Capítulo 2

Física de Altas Energias e o Projeto LHC

Como se sabe, tudo no universo é formado por partículas elementares, governadas por poucas forças fundamentais. Algumas destas partículas são estáveis e formam a matéria conhecida. Já as partículas instáveis duram apenas frações de segundo antes de decaírem em partículas estáveis. Ambas as classes de partículas coexistiram por um breve momento após o *Big Bang*. Desde então, para fazer com que estas partículas instáveis sejam novamente observadas, uma maneira é colidir partículas com enorme quantidade de energia, recriando, em laboratório e em pequena escala, o ambiente do *Big Bang*.

Para recriar tal ambiente, os físicos utilizam colisionadores de partículas, os quais são compostos por dutos onde um feixe de partículas é acelerado à velocidades bastante elevadas, de forma a aumentar consideravelmente a energia destas. Quando a energia chega a um ponto suficientemente elevado, o feixe é posto para colidir com um outro grupo de partículas, recriando, no momento da colisão, o ambiente propício para a formação de partículas instáveis. Com isto, pretende-se avançar no estudo da estrutura da matéria. Normalmente, são utilizados prótons ou elétrons no feixe a ser acelerado.

Three Generations of Matter (Fermions)				
	I	II	III	
mass→	2.4 MeV	1.27 GeV	171.2 GeV	0
charge→	$\frac{2}{3}$	$\frac{2}{3}$	$\frac{2}{3}$	0
spin→	$\frac{1}{2}$	$\frac{1}{2}$	$\frac{1}{2}$	1
name→	u up	c charm	t top	γ photon
Quarks	4.8 MeV	104 MeV	4.2 GeV	0
	$-\frac{1}{3}$	$-\frac{1}{3}$	$-\frac{1}{3}$	0
	$\frac{1}{2}$	$\frac{1}{2}$	$\frac{1}{2}$	1
	d down	s strange	b bottom	g gluon
Leptons	<2.2 eV	<0.17 MeV	<15.5 MeV	91.2 GeV
	0	0	0	0
	$\frac{1}{2}$	$\frac{1}{2}$	$\frac{1}{2}$	1
	ν_e electron neutrino	ν_μ muon neutrino	ν_τ tau neutrino	Z⁰ weak force
	0.511 MeV	105.7 MeV	1.777 GeV	80.4 GeV
	-1	-1	-1	± 1
	$\frac{1}{2}$	$\frac{1}{2}$	$\frac{1}{2}$	1
	e electron	μ muon	τ tau	W[±] weak force
				Bosons (Forces)

Figura 2.1: Modelo padrão de partículas elementares.

2.1 O Modelo Padrão

As teorias e descobertas de milhares de físicos durante o século passado criaram uma notável imagem da estrutura fundamental da matéria: o Modelo Padrão de Partículas e Forças [1]. O Modelo Padrão utiliza 12 partículas elementares e 4 partículas transportadoras de força para resumir tudo o que é atualmente conhecido sobre os mais fundamentais constituintes da matéria e suas interações (vide Figura 2.1). O Modelo Padrão é, por hora, uma teoria física bem testada, usada para explicar e prever uma vasta variedade de fenômenos. Entretanto, os físicos sabem que existem teorias ainda não confirmadas, de tal forma que diferentes experimentos ainda devem ser realizados para confirmá-las.

2.1.1 Partículas Materiais

Existem duas famílias de partículas materiais descritas no modelo padrão: os quarks e os léptons, ambos sem estrutura interna:

- **Quarks:** são 6, frequentemente agrupados em 3 pares, devido às suas propriedades de massa e carga:

- *up / down*
- *charm / strange*
- *top / bottom*

• **Léptons:** são 6, agrupados em duas categorias, cada uma contendo 3 tipos:

- **Com carga e massa:** elétron (e^-), múon (μ) e tau (τ).
- **Neutras e com massa reduzida:** elétron-neutrino (V_e), múon-neutrino (V_μ) e tau-neutrino (V_τ).

Como os nomes desta categoria sugerem, estas 6 partículas também podem ser agrupadas em três pares (μ^- / V_μ , por exemplo.)

A matéria estável do universo é formada apenas pelos pares mais leves e^- / V_e e *up / down*, formando a chamada primeira geração da matéria. Entretanto, processos de alta energia produzem uma grande variedade de partículas de vida curta, que requerem a existência de pares mais pesados. Assim, tem-se os pares μ / V_μ e *charm / strange*, que formam a segunda geração, enquanto que os pares τ / V_τ e *top / bottom* formam a terceira geração da matéria.

2.1.2 Partículas Transportadoras de Força

O Modelo Padrão considera 3 tipos de forças atuando entre partículas: força forte, fraca e eletromagnética (a gravidade ainda não é parte do modelo).

As forças são comunicadas entre as partículas através da troca de partículas transportadoras de força, chamadas de *bósons*, que carregam uma quantidade discreta de energia de uma partícula a outra. Cada força tem seus próprios bósons característicos: o glúon (força forte), o fóton (força eletromagnética) e os bósons W e Z (força fraca).

2.1.3 Estendendo o Modelo Padrão

O Modelo Padrão é, atualmente, a melhor descrição que se tem do mundo das partículas. Entretanto, existem importantes teorias que, por falta de comprovação experimental, ainda não puderam ser incluídas no Modelo Padrão. Alguns exemplos são:

O Bóson de Higgs

Partículas possuem uma vasta variedade de massas. Fótons e glúons são completamente desprovidos de massa, enquanto que as partículas W e Z pesam, cada uma, tanto quanto 85 e 95 prótons, respectivamente. A partícula mais pesada descoberta até agora, o quark *top*, é duas vezes mais pesado que os bósons W e Z , pesando aproximadamente o mesmo que um núcleo de ouro. Entretanto, o porquê da existência desta larga faixa para as massas ainda é um mistério. De fato, a maneira como as partículas adquirem massa ainda não é devidamente compreendida.

No Modelo Padrão, sugere-se que as partículas ganhem massa através do mecanismo de Higgs [2]. De acordo com esta teoria, tanto as partículas de matéria como as transportadoras de forças interagem com uma nova partícula, o *Bóson de Higgs*. A força desta interação é o que dá lugar ao que se chama de massa. Ou seja: quanto maior a interação, maior a massa.

Antimatéria

Além das partículas que compõem o modelo padrão, foi verificado experimentalmente a existência de antipartículas, que são partículas que têm todas as características em comum com estas, mas com números quânticos (como carga) invertidos. Desta forma, assim como existe a partícula múon, existe o antimúon, e o elétron possui o pósitron¹.

A teoria diz que, quando uma partícula encontra sua antipartícula, ambas se aniquilam, liberando energia neste processo. Adicionalmente, matéria e antimatéria coexistiram por um breve momento após o Big Bang. Conseqüentemente, era de se esperar que toda a matéria do universo tivesse se aniquilado com sua respectiva antimatéria, de forma que o universo hoje seria formado apenas por energia. Visto que este fenômeno não ocorreu, diversas teorias foram desenvolvidas para tentar explicar esta incoerência.

Matéria Escura

Observações astronômicas da rotação de galáxias mostraram que estas giram mais rapidamente do que seria esperado, de acordo com a teoria de gravitação. Este

¹O antielétron é chamado de pósitron por razões históricas.

estranho efeito gravitacional revelou a existência de uma matéria não observável por meios conhecidos (radiação eletromagnética, por exemplo). A esta matéria, deu-se o nome de matéria escura.

É estimado que a matéria escura componha 26% do universo. Pesquisadores acreditam que o efeito gravitacional da matéria escura faz as galáxias girarem mais rápido, e que o seu campo gravitacional desvia a luz de objetos atrás da mesma. Entretanto, embora a existência da matéria escura já tenha sido inferida, não se sabe ainda de que é composta esta matéria.

2.2 O Projeto LHC (*Large Hadron Collider*)

O LHC [3] é um novo acelerador que entrou em operação em 2009. Com seus imãs poderosos e possuindo incríveis 27 km de circunferência, ele será capaz de atingir níveis de energia nunca antes alcançados, devendo colidir pacotes (com um número elevado de prótons) com 14 TeV no centro de massa. Com esta energia, espera-se tornar possível estudar a estrutura da matéria, e fenômenos tais como os descritos na Seção 2.1.3

Os prótons são acelerados em tubos a vácuo em túneis subterrâneos (100 metros de profundidade). Eles são mantidos em órbitas aproximadamente circulares por fortes campos magnéticos produzidos por imãs supercondutores. Entretanto, quanto maior a energia, maior a órbita das partículas, e, conseqüentemente, maior o túnel. Desta maneira, o LHC (vide Figura 2.2) constitui o maior acelerador de partículas do mundo.

Como os feixes de prótons trafegam por tubos separados, para colidi-los é feito o seguinte: em pontos específicos do acelerador, chamados de “pontos de colisão”, não existem campos magnéticos, de forma que, nestas regiões, os feixes percorrem uma trajetória retilínea. Desta maneira, os dois feixes podem ser reunidos em um ambiente a vácuo e postos, finalmente, em rota de colisão.

Os prótons são inseridos no acelerador em pacotes (*bunches*) com poucos centímetros de comprimento e alguns micrômetros de raio. A distância entre um pacote e outro é de 7,5 metros. Uma vez que a luz demora 25 nanossegundos para percorrer 7,5 metros, e os prótons estão praticamente se movendo à velocidade da luz,

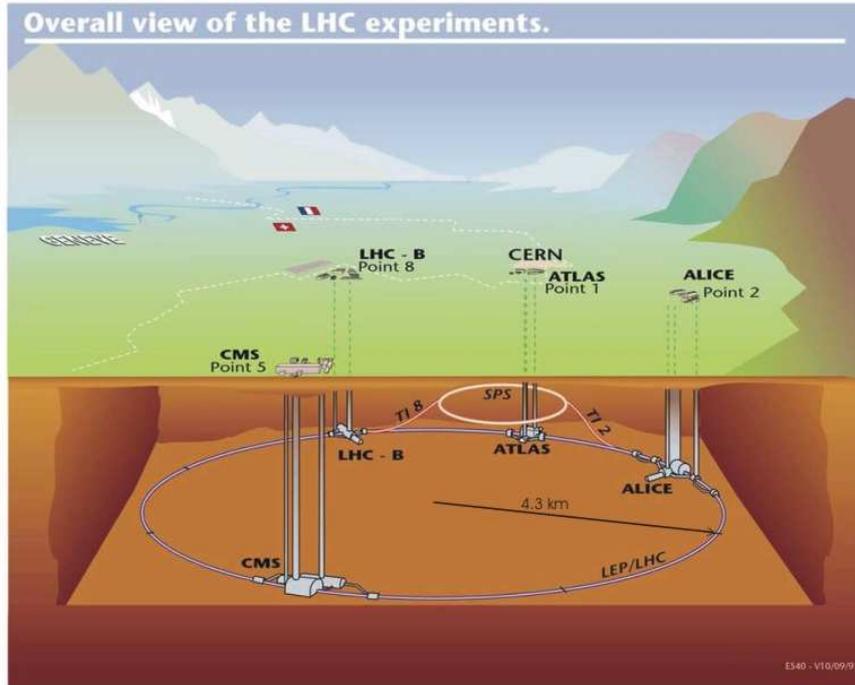


Figura 2.2: Vista aérea do LHC (extraído de [4]).

conclui-se que os pacotes irão cruzar-se (e os prótons colidirem) com uma frequência de 40 MHz^2 . Entretanto, o número de colisões entre prótons depende da quantidade de prótons em cada pacote, da seção transversal dos prótons, e do desenho do acelerador. Para uma alta taxa de colisões, deve-se ter pacotes de curto comprimento, muitos prótons em cada pacote e muitos pacotes por unidade de tempo. Estas propriedades, que dependem do projeto do acelerador, podem ser combinadas em um único parâmetro: *luminosidade*.

A luminosidade é definida como o número de partículas por unidade de área, por unidade de tempo, vezes a opacidade do alvo, expressa, normalmente em $\text{cm}^{-2} \text{ s}^{-1}$. Para um acelerador circular, a luminosidade é definida como

$$L = fn \frac{N_1 N_2}{A} \quad (2.1)$$

onde f é a frequência de colisões, n é o número de pacotes de partículas que compõem o feixe, N_i é o número de partículas em cada pacote e A é a área da seção transversal do feixe.

Em física experimental de partículas, atingir níveis elevados de luminosidade é

²A esta taxa, dá-se o nome, em inglês, de *bunch crossing rate*.

tão importante quanto atingir níveis elevados de energia. Isto ocorre porque nem todas as colisões produzem os mesmos efeitos, e os tipos de colisões que geram eventos de interesses são extremamente raros. Por isso, são necessárias muitas colisões distintas (ou seja, alta luminosidade) para que se aumente a probabilidade de observação de eventos de interesse. No LHC, espera-se, com a luminosidade de operação ($1 \times 10^{34} \text{ cm}^{-2} \text{ s}^{-1}$ [3]), atingir um total de um bilhão de colisões por segundo, sendo que deste valor, apenas um número entre 10 e 100 colisões poderão vir a ser de potencial interesse científico. No caso do bóson de Higgs, por exemplo, dada a sua raridade, esta taxa pode cair para um valor tão baixo que serão necessárias horas, e até mesmo dias, para que um único decaimento deste tipo possa vir a ocorrer.

Entretanto, para que seja possível aos físicos realizar as análises necessárias nos eventos gerados durante a colisão, sistemas de detecção devem ser posicionados em torno dos pontos de colisão para realizar a captura dos eventos gerados, e convertê-los em informação interpretável para os físicos. Visando este fim, o LHC possui diversos detetores:

- **ATLAS (*A Toroidal LHC Apparatus*)** → Este experimento, composto por vários detetores, será capaz de estudar diversos fenômenos, tal como os mencionados na Seção 2.1.3. Detalhes deste experimento serão vistos na Seção 2.3.
- **CMS (*Compact Muon Solenoid*)** → A maioria dos detetores em física de partículas estão posicionados em torno de dispositivos magnéticos, de forma a tornar possível medir o momento de partículas carregadas. Este experimento contará com um solenóide supercondutor capaz de gerar um campo magnético de 4T (cem mil vezes maior do que o campo magnético da Terra), permitindo que dispositivos de detecção de traços e calorimetria sejam inseridos dentro das espiras do solenóide gerador do campo magnético, resultando em um poderoso detetor de uso geral, com ênfase na detecção de múons [5].
- **LHCb (*A High Energy Physics Experiment Studying CP Violation*)** → Este experimento visa estudar a violação CP³ [6]. Com o detetor

³A antimatéria nem sempre se comporta como uma imagem espelhada da matéria, de tal forma

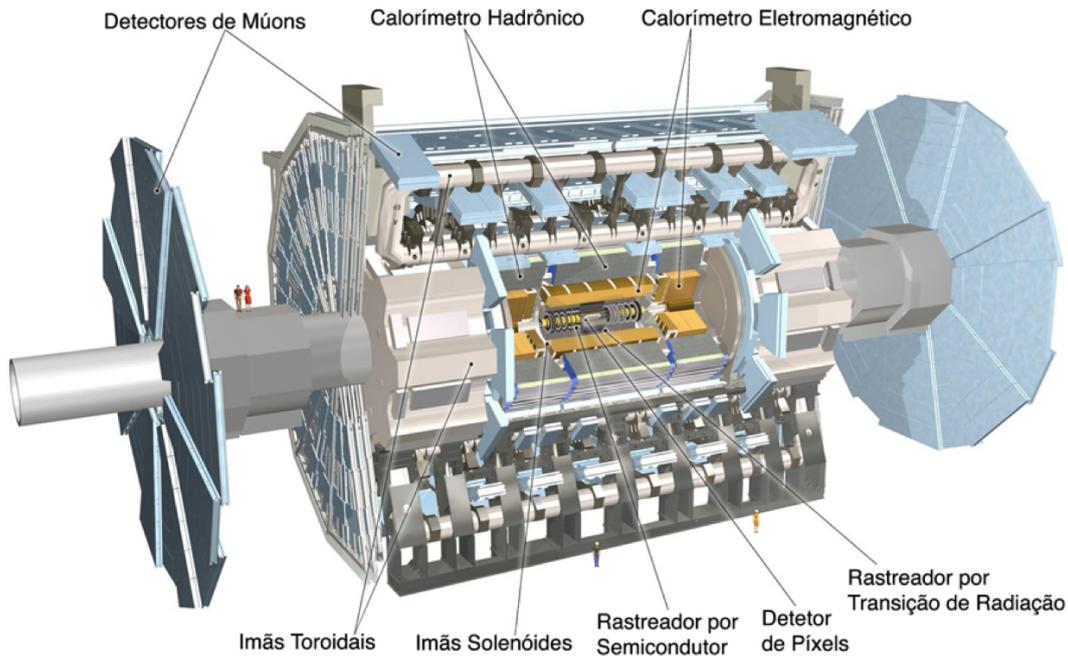


Figura 2.3: Diagrama ilustrativo do detector ATLAS (extraído de [10]).

sendo desenvolvido neste experimento, os físicos serão capazes de detectar minúsculas diferenças entre matéria e antimatéria [7].

- **ALICE (*A Large Ion Collider Experiment*)** → O detector ALICE é dedicado a íons pesados, explorando as interações entre núcleos atômicos ocorridas à energias elevadas, como as fornecidas pelo LHC. O objetivo é estudar a física de matérias fortemente interativas a densidades de energia elevadíssimas, onde se espera a formação de uma nova fase da matéria: o plasma quark-glúon [8].
- **TOTEM (*Total Cross Section, Elastic Scattering and Diffraction Dissociation*)** → Este experimento é dedicado a medir a seção transversal total, dispersão elástica e processos difrativos no LHC. Com isso, espera-se fornecer uma calibração exata da luminosidade do LHC [9].

2.3 O Detetor ATLAS (*A Toroidal LHC Apparatus*)

Quando prótons colidem, alguns dos eventos gerados podem trazer informações relevantes ao objetivo do experimento, enquanto que muitas outras colisões ordinárias (que não trazem nenhuma informação nova e, por isso, são comumente tratadas como ruído de fundo da experiência) são adquiridas. Assim, uma das principais necessidades de experimentos realizados com aceleradores de partículas é a separação dos eventos de interesse dos eventos de física ordinária. A diferenciação entre eventos é baseada nos subprodutos observados em cada colisão, dos quais se extraem grandezas tais como energia, direção de movimento, etc. Para se identificar os eventos de interesse, torna-se necessário um poderoso detetor, que fornecerá informação detalhada sobre os subprodutos obtidos através das colisões realizadas no LHC, e de um complexo sistema de filtragem que, analisando a informação lida pelo detetor, buscará encontrar informação de interesse e rejeitar, tanto quanto possível, o ruído de fundo. Este é o caso do detetor ATLAS [11]. O projeto deste detetor é o maior esforço colaborativo jamais visto na física, envolvendo 1800 cientistas de mais de 150 universidades em 37 países.

Observa-se, na Figura 2.3, um diagrama ilustrativo do detetor ATLAS, dando idéia de suas dimensões (22 metros de altura, 44 metros de comprimento e 7000 toneladas). Este detetor está dividido em módulos distintos, conforme se pode analisar observando-se a seção transversal do mesmo, apresentada na Figura 2.4, onde cada número indica um módulo específico, a saber:

1. **Tubo do Feixe:** o tubo do feixe passa através do centro do detetor e carrega os feixes de prótons. Feixes viajando em sentido contrário através deste tubo, são postos a colidir no meio do detetor.
2. **Detetor de Traços:** a região interna do detetor está repleta de sensores altamente segmentados feitos de tiras de silício, de forma que as trajetórias das partículas carregadas possam ser precisamente determinadas. A trajetória de uma partícula carregada é curva, se a mesma estiver sob a influência de um

que a este fenômeno dá-se o nome de violação CP.

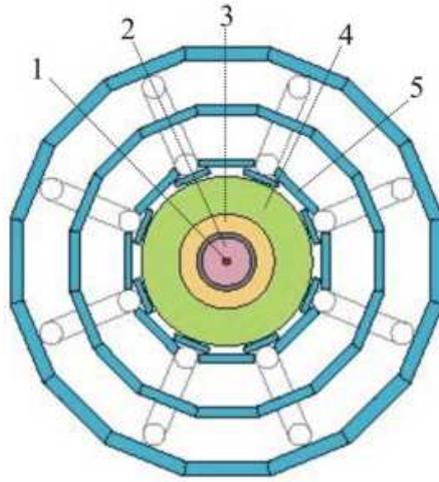


Figura 2.4: Seção transversal do detector ATLAS (extraído de [12]).

campo magnético, como é o caso no ATLAS. O raio da curvatura e a direção da deflexão indicam, respectivamente, o momento e a carga da partícula.

3. **Calorímetro Eletromagnético:** determina a energia e o perfil de deposição de energia de partículas eletromagnéticas (elétrons e fótons). Possui fina granularidade e está dividido em quatro camadas, cada uma com granularidade distinta. Este calorímetro será apresentado em maiores detalhes na Seção 3.3.3.
4. **Calorímetro Hadrônico:** determina a energia e o perfil de deposição de energia de partículas hadrônicas (prótons, píons, káons, etc.). Tal como o calorímetro eletromagnético, possui várias camadas (três) com granularidades distintas. O calorímetro hadrônico será apresentado em maiores detalhes na Seção 3.3.3.
5. **Detetor de Múons:** múons interagem como qualquer partícula carregada. Entretanto, como são cerca de 200 vezes mais pesados do que elétrons, estas partículas são muito menos afetadas pelo campo elétrico dos átomos que estejam no caminho desta partícula. Desta forma, múons dissipam pouca energia, e somente através da ionização de átomos que estejam em seu caminho. Assim, qualquer partícula energética que chegue a este detetor é classificada como múon ou neutrino⁴, visto que as demais partículas foram totalmente ab-

⁴Entretanto, neutrinos também não interagem com este detetor, escapando do mesmo. A presença de neutrinos, desta forma, só pode ser inferida pela energia que sobra do processo.

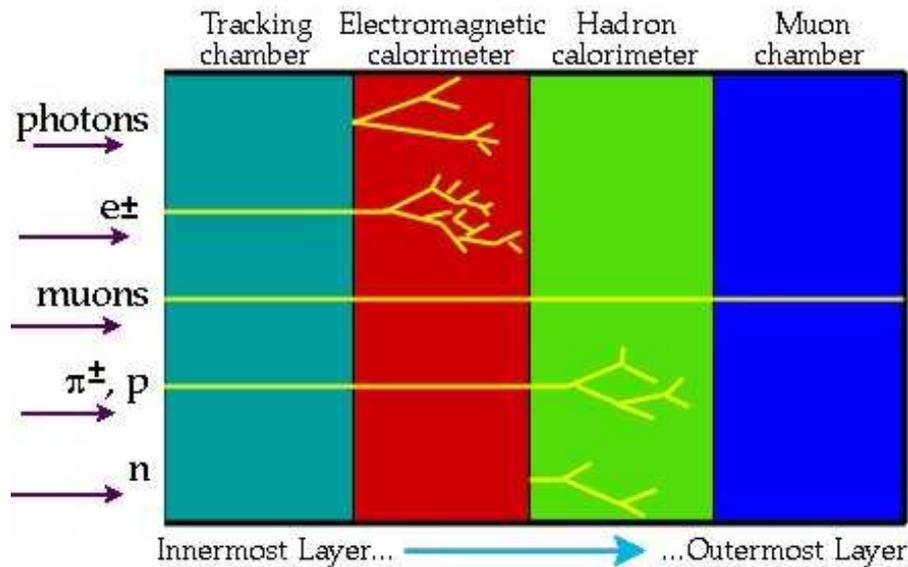


Figura 2.5: Interação de diferentes partículas com os diversos módulos do detector ATLAS.

sorvidas pelos calorímetros. Adicionalmente, o elevado momento dos múons faz com que o traço deixado pelos mesmos no detector de traços seja retilíneo, visto que não há campo magnético suficiente para alterar a trajetória desta partícula no espaço relativamente pequeno do detector de traços. Para resolver este problema, o detector de múons conta, também, com um poderoso sistema de detecção de traços específico para este tipo de partícula.

Cada módulo observará um conjunto específico de propriedades das partículas. Estes módulos são empilhados de tal forma que as partículas possam percorrer todas as camadas sequencialmente. Uma partícula não se tornará visível até que interaja com uma ou mais camadas do detector, ou que se decomponha em partículas que o façam. Pode-se visualizar, na Figura 2.5, um exemplo de interação de diversas partículas com as diferentes camadas (módulos) do detector. Como se pode observar, partículas carregadas, como prótons e elétrons, são detectadas tanto na câmara de traços, bem como no calorímetro eletromagnético. Partículas neutras, como nêutrons e fótons, não são detectadas na câmara de traços, só sendo observadas quando interagem com outras camadas do detector. Fótons são detectados somente no calorímetro eletromagnético, enquanto que nêutrons são detectados somente no calorímetro hadrônico. Múons, finalmente, passam praticamente sem interagir com

todas as camadas de detecção do ATLAS, motivo pelo qual a câmara de múons foi concebida. Ou seja, cada partícula deixa a sua própria assinatura, ao interagir com um ou mais módulos do detetor. E a combinação da assinatura deixada em cada detetor torna possível a identificação das mesmas durante a filtragem destas, como será visto nos próximos capítulos.

Capítulo 3

Introdução à Calorimetria

Em física de partículas, calorimetria se refere à detecção de partículas e à medida de suas propriedades através da absorção total destas em um bloco de matéria chamado calorímetro [13]. Existem calorímetros de diversos tipos, mas todos têm em comum o fato de que o processo de detecção de partículas empregado é destrutivo, ou seja, após a interação de uma partícula com o calorímetro, nada mais pode-se medir sobre a mesma¹.

Em experimentos envolvendo colisionadores, calorímetros são idealmente adequados para prover informação sobre a energia de partículas incidentes, bem como o perfil de deposição desta energia em um tempo da ordem de nanossegundos [13]. Como o sinal produzido por um calorímetro depende muito do tipo de partícula incidente, este tipo de detetor oferece grandes possibilidades para a seleção de eventos, de acordo com a física que se deseja reter / identificar [14].

Em relação à sua composição, calorímetros podem ser homogêneos ou por amostragem [13]. Nos calorímetros homogêneos, todo o volume do mesmo é sensível à partícula incidente, contribuindo para a produção do sinal gerado no detetor. Os calorímetros por amostragem possuem um material passivo, responsável por absorver a energia da partícula incidente, e um material ativo, que produz o pulso de luz ou carga usado para a detecção.

No que tange a acurácia das medidas de energia, sabe-se [13] que a mesma

¹A única exceção à esta regra são os múons.

aumenta com a energia da partícula incidente, de acordo com a fórmula empírica

$$\frac{\sigma_E}{E} \approx \frac{a}{\sqrt{E}} + b \quad (3.1)$$

onde E é a energia da partícula incidente e σ_E representa o desvio padrão da medida de energia e a e b são constantes que dependem do tipo de detetor, por exemplo, sua espessura e características das camadas ativas e passivas.

3.1 Interação de Partículas com o Calorímetro

Os processos de interação mais importantes dependem da energia e da natureza da partícula incidente. Eles são resultados das forças eletromagnética, forte, e fraca² que reinam entre a partícula e o material passivo do calorímetro.

3.1.1 Absorção de Partículas Eletromagnéticas

O mecanismo de absorção de energia mais conhecido é a interação eletromagnética experimentada por partículas carregadas (elétrons ou pósitrons) atravessando a matéria. Estas partículas ionizam o meio, se sua energia for suficiente para liberar elétrons dos campos de Coulomb gerados pelo núcleo dos átomos. Este processo forma o princípio sobre o qual muitos detetores de partículas são baseados, uma vez que os elétrons liberados podem ser coletados por meios de um campo elétrico, produzindo um sinal elétrico [15]. A interação eletromagnética pode se manifestar, contudo, em várias outras maneiras [15]:

- Partículas carregadas podem excitar átomos ou moléculas sem necessariamente ionizá-las. Átomos em estado excitado são instáveis, retornando rapidamente ao seu estado relaxado. Neste processo de retorno ao seu estado original, a energia de excitação é liberada na forma de fótons. A este processo, dá-se o nome de *cintilação*.
- Partículas carregadas viajando em velocidades mais altas do que a luz no mesmo meio podem perder energia através da emissão de luz de Čerenkov [16].

²Esta mais raramente.

- Em altas energias, elétrons podem ser arrancados do átomo do meio (*knock-on electrons*), produzindo raios δ .
- Em altas energias, pode-se observar efeitos de *bremstrahlung* [15]. Neste processo, elétrons e pósitrons irradiam fótons como resultado da interação Coulombiana destes com o campo elétrico gerado pelo núcleo dos átomos do meio.
- Em energias muito elevadas, a interação eletromagnética pode induzir reações nucleares.

Além de partículas carregadas, tais como elétrons e pósitrons, fótons também podem produzir interação eletromagnética com o meio sobre o qual incidem de diversas maneiras [15]:

- O processo mais comum em baixas energias é o *efeito fotoelétrico*. Neste efeito, um átomo do meio absorve o fóton, e emite um elétron. O átomo, então, fica em estado excitado, voltando ao estado relaxado através da emissão de novos elétrons (*Auger electrons*) ou raios-X.
- O fóton incidente pode atingir um elétron, fornecendo parte de sua energia ao mesmo, que libera outro fóton de mais baixa energia, em um processo conhecido como *espalhamento Compton*.
- Sob a ação do campo de uma partícula carregada, um fóton pode produzir um par elétron-pósitron, um fenômeno conhecido como *produção de pares*. Este par, por sua vez, perderá energia através de fenômenos relacionados à absorção de energia de partículas carregadas.

Em física de altas energias, *bremstrahlung* é, de longe, a principal forma de perda de energia de elétrons e pósitrons. Um elétron com vários GeV de energia pode irradiar milhares de fótons ao cruzar pelo material passivo do calorímetro. A esmagadora maioria destes fótons é absorvida por espalhamento Compton e efeito fotoelétrico. Fótons com energias maiores que 5-10 MeV criam pares elétrons-pósitrons. Estes pares criados perdem sua energia liberando mais fótons, que podem produzir novos pares elétrons-pósitrons. Esta sequência de produção de eventos é chamada

de *chuveiro eletromagnético* [13]. Ao longo da evolução deste chuvaire, a energia média das partículas do mesmo diminui até o ponto onde não há mais multiplicação de partículas. A partir deste ponto (conhecido como ponto máximo do chuvaire), o número de partículas do chuvaire começa a diminuir, visto que a energia das partículas não é mais suficiente para produzir novos pares. Como processos de absorção em baixas energias não produzem pósitrons, somente elétrons, tem-se que, tipicamente, 75% da energia total do chuvaire é depositada por elétrons, e o resto, por pósitrons [13].

3.1.2 Absorção de Partículas Hadrônicas

O processo de absorção de partículas hadrônicas ocorre através da interação forte destas com o núcleo do átomo do meio. Devido à natureza das interações fortes, a absorção de partículas hadrônicas é um processo bem mais complicado do que a absorção de partículas eletromagnéticas. A variedade de processos que podem ocorrer, tanto do ponto de vista das partículas, bem como processos envolvendo o núcleo atômico atingido, é muito maior.

Na interação eletromagnética, a energia da partícula é perdida em uma cadeia contínua de eventos. Quando um hádron de alta energia penetra um bloco de matéria, o mesmo fenômeno pode ocorrer. Quando o hádron é carregado, ele ionizará os átomos do meio em que incide em uma sequência contínua de eventos. Contudo, em algum ponto da interação, o hádron encontrará um núcleo com o qual interagirá através da força forte, podendo mudar sua identidade radicalmente (por exemplo, formando 15 novos hádrons). O núcleo atingido também sofrerá alterações, podendo, por exemplo, perder nêutrons e prótons neste processo, terminando em um estado altamente excitado e, finalmente, retornando ao seu estado relaxado através da emissão de raios γ .

Como hádrons neutros não ionizam o meio atravessado, a reação nuclear é a única opção para o meio absorver a energia destes. As partículas produzidas nas primeiras reações nucleares (mésons, γ , etc.) podem perder sua energia através da ionização do meio e/ou induzir novas reações nucleares, produzindo uma cascata de eventos similar à produzida para partículas eletromagnéticas. Para partículas hadrônicas, este processo denomina-se *chuveiro hadrônico* [13]. Inicialmente, o

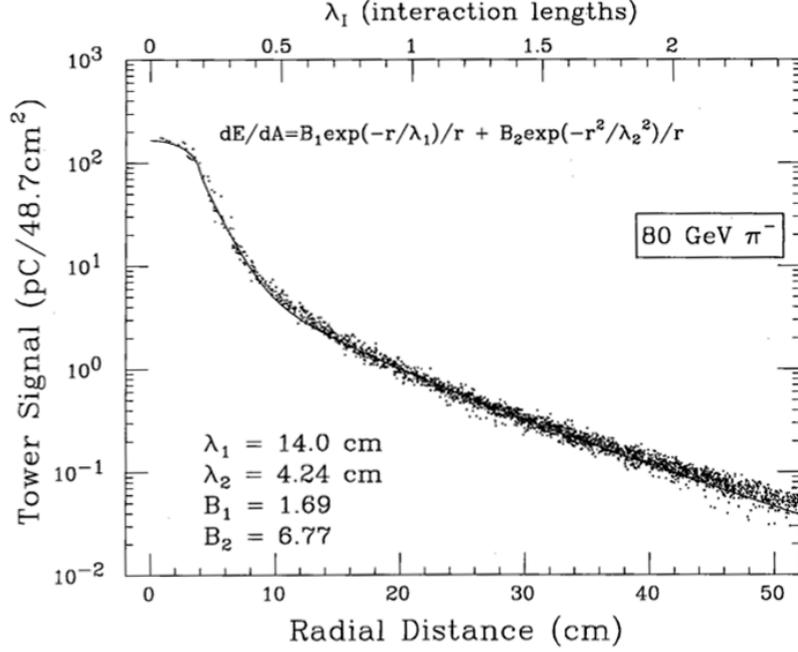


Figura 3.1: Perfil lateral médio do chuveiro produzido por píons de 80 GeV (extraído de [17]).

número de partículas aumenta, devido ao processo de multiplicação. A partir de certo ponto (o máximo do chuveiro), as multiplicações subsequentes são balanceadas pela absorção de partículas do chuveiro, fazendo com que o número de partículas do chuveiro caia gradativamente.

Alguns aspectos a respeito do chuveiro hadrônico trazem importantes consequências para a calorimetria. Algumas das partículas produzidas na cascata hadrônica, em particular π^0 e η , decaem através de interações eletromagnéticas: $\pi^0, \eta \rightarrow \gamma\gamma$. Desta forma, cascatas hadrônicas geralmente contêm um componente que se propaga eletromagneticamente. Outra característica do chuveiro hadrônico é que o mesmo avança, para um mesmo meio, muito mais profundamente do que um chuveiro eletromagnético. Adicionalmente, o chuveiro hadrônico apresenta um perfil lateral bem mais largo daquele produzido por uma partícula eletromagnética. Como exemplo, é apresentado, na Figura 3.1, o perfil lateral médio da deposição de píons (π^-), que são partículas hadrônicas, em um calorímetro utilizando cintiladores como material ativo e chumbo como material absorvedor [17]. O eixo das abcissas é a distância (em cm, na parte inferior) lateral em relação ao eixo do chuveiro. O eixo das ordenadas apresenta a energia depositada para uma dada distância. O

núcleo estreito representa o componente eletromagnético do chuveiro, produzido pelos π^0 originados durante o desenvolvimento do chuveiro. A cauda, com decaimento exponencial, é causada pelos componentes não-eletromagnéticos do chuveiro.

3.2 Identificação de Partículas Baseada em Calorimetria

Conhecendo-se as diferenças entre as características do perfil de deposição de energia, os sinais produzidos por calorímetros podem ser utilizados para identificar as partículas que os produziram. Em física de altas energias, elétrons de alta energia têm sido poderosos indicadores de física de interesse, tendo tido um papel fundamental na descoberta de muitos quarks pesados, o lépton τ e bósons vetores intermediários [18].

Especialmente em colisionadores hadrônicos, tais como o LHC, elétrons de interesse são produzidos em quantidade muitas ordens de grandeza abaixo do número de hádrons e fótons produzidos, na mesma faixa de energia. Conseqüentemente, o sucesso de experimentos com colisionadores hadrônicos depende grandemente da eficiência de detecção de elétrons nesta difícil condição.

A identificação de elétrons em colisionadores hadrônicos é feita em duas etapas:

1. Determinar se o sinal obtido foi causado por um chuveiro eletromagnético, e não hadrônico.
2. Determinar se o sinal foi causado por um elétron e não por fótons.

A segunda etapa requer a associação do sistema de calorimetria com um sistema capaz de identificar a trajetória de partículas carregadas. Por exemplo, uma partícula que tenha produzido um chuveiro eletromagnético, mas que apresente uma trajetória retilínea levaria a conclusão de que se trata de um fóton.

Para determinar-se se o chuveiro produzido é eletromagnético ou hadrônico, pode-se explorar os perfil longitudinal e lateral de chuveiros eletromagnéticos e hadrônicos. Em [13], mostra-se que o chuveiro eletromagnético e hadrônico escala

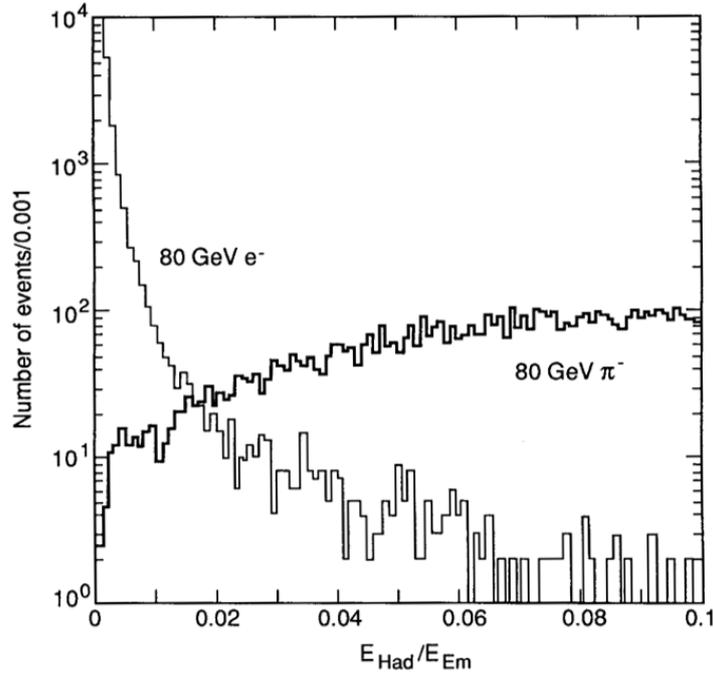


Figura 3.2: Exemplo da distribuição da razão de energia depositada nas seções hadrônicas e eletromagnéticas de um sistema de calorimetria, para elétrons e píons de 80 GeV (extraído de [20]).

(aproximadamente) com o comprimento de radiação³ (X_0) e com o comprimento de interação nuclear⁴ (λ_{int}), respectivamente. Desta forma, a distinção entre elétrons e hádrons funciona melhor em materiais com X_0 e λ_{int} bem diferentes. Materiais com número atômico (Z) elevado, tais como urânio, chumbo e tungstênio, são os que apresentam as melhores distinções entre X_0 e λ_{int} , sendo frequentemente utilizados em sistemas de calorimetria [19].

3.2.1 Identificação Baseada na Informação Longitudinal

Em praticamente todos os experimentos que utilizam calorímetros para a identificação de elétrons, as diferenças entre o desenvolvimento longitudinal dos chuveiros eletromagnéticos e hadrônicos é explorada. Esta é a principal razão prática para que sistemas de calorimetria sejam divididos em seções eletromagnéticas e hadrônicas.

³Comprimento de radiação é a distância necessária para que um elétron ou pósitron perca 63,2% de sua energia por *bremsstrahlung*, em um dado material.

⁴Comprimento de interação nuclear é o comprimento médio necessário para que, em um dado material, um hádron de alta energia produza uma interação nuclear.

Este potencial de separação fica evidente na Figura 3.2, onde se apresenta a distribuição da razão de energia depositada nas seções eletromagnéticas e hadrônicas do calorímetro projetivo RD1 [20] para elétrons e píons com 80 GeV de energia. Informações ainda mais detalhada sobre o perfil longitudinal do chuveiro podem ser obtidas se ambas seções eletromagnética e hadrônica, forem segmentadas em múltiplas seções longitudinais [21].

A principal limitação para o nível de separação baseada na informação longitudinal provém da física do processo. Reações com troca de cargas do tipo $\pi^- + p \rightarrow \pi^0 + n$ e $\pi^+ + n \rightarrow \pi^0 + p$ produzem somente chuveiros eletromagnéticos se todo o momento carregado pelos píons com carga for transferido para os píons neutros. Quando este tipo de reação ocorre logo nos primeiros X_0 do calorímetro, os chuveiros resultantes são praticamente indistinguíveis daqueles produzidos por elétrons.

3.2.2 Identificação Baseada na Informação Lateral

Além da informação longitudinal, a informação lateral também pode ser usada para a identificação de chuveiros eletromagnéticos. Em calorímetros com fina granularidade, esta técnica pode apresentar excelentes resultados. Em [22], apresenta-se uma técnica de identificação de elétrons baseada no perfil lateral de deposição de energia em um calorímetro sem nenhuma segmentação longitudinal. Para tal, definiu-se uma quantia que mede o tamanho do perfil lateral do chuveiro produzido fazendo-se

$$R_p = \frac{\sum_i r_i E_i^{0,4}}{\sum_i E_i^{0,4}} \quad (3.2)$$

onde E_i representa a energia depositada em cada célula do calorímetro, e r_i a distância desta célula ao baricentro do chuveiro gerado. Como chuveiros hadrônicos apresentam um perfil lateral mais largo, espera-se que produzam valores de R_p maiores do que os obtidos por chuveiros eletromagnéticos. A distinção entre ambos fica clara na Figura 3.3, onde se apresenta a distribuição de valores de R_p obtidos para elétrons e píons com 80 GeV de energia.

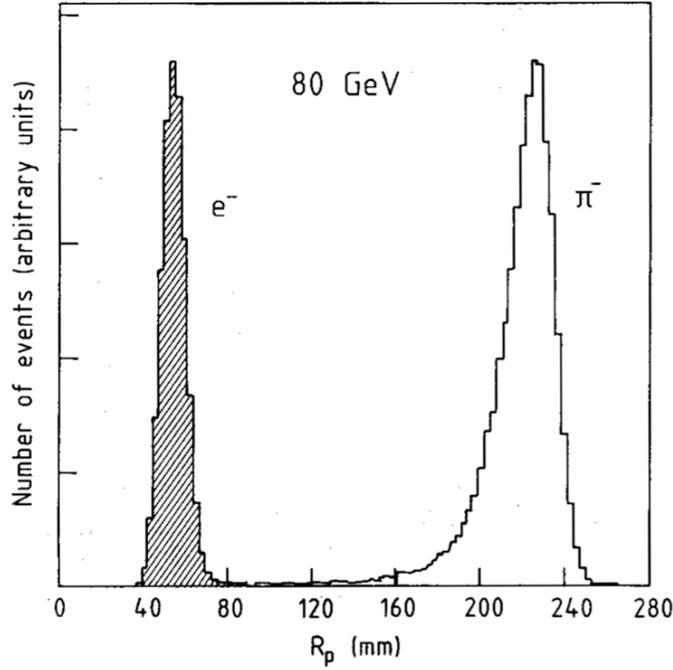


Figura 3.3: Exemplo da distribuição do R_p , para elétrons e píons de 80 GeV (extraído de [22]).

3.2.3 Detetores de Pré-Irradiadores (*Pre-Showers*)

Como visto, a grande diferença entre X_0 e λ_{int} em materiais com Z elevado pode ser explorada com sucesso no processo de identificação de elétrons. Na Figura 3.2, esta diferença manifesta-se na forma de perfis de deposição de energia bastante distintos entre as seções longitudinais do calorímetro, para chuviros induzidos por elétrons e píons, respectivamente.

Entretanto, mesmo em materiais muito mais finos do que o necessário para a completa absorção do chuviro de partículas, as diferenças (logo nos primeiros estágios) entre chuviros eletromagnéticos e hadrônicos oferecem possibilidades para a separação e/π . Esta característica forma o princípio básico de funcionamento dos detetores de *pre-shower* [13].

Um detetor de *pre-shower* bastante simples pode ser constituído por uma fina pastilha de chumbo, com espessura de 1 cm ($X_0 = 1,6$ e $\lambda_{int} = 0,06$), com uma camada de material cintilante como material ativo. Quando um feixe de elétrons e píons de alta energia atinge este calorímetro, quase todos os píons ($\sim 96\%$) atravessam este detetor sem grandes interações, produzindo um pico de ionização bastante discreto no cintilador. Elétrons, ao contrário, perdem uma considerável fração de

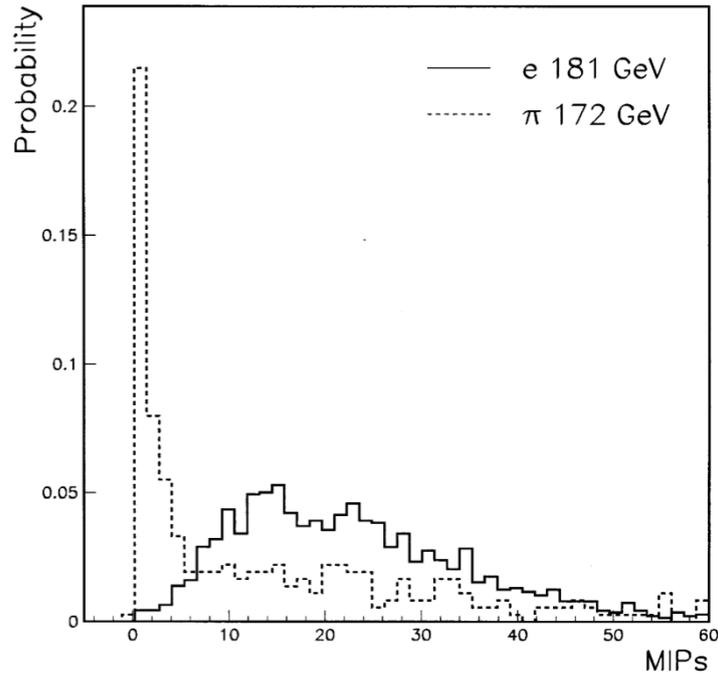


Figura 3.4: Exemplo de resposta de um detetor de *pre-shower* para elétrons e píons (extraído de [23]).

sua energia ao irradiarem uma grande quantidade de fótons produzidos por *bremsstrahlung*. Uma parte destes fótons serão convertidos em pares e^+e^- no material passivo, contribuindo para o sinal que será produzido no cintilador. O resultado é uma clara distinção entre elétrons e píons.

É apresentada, na Figura 3.4, a distribuição de sinal obtida, em função do número de MIPs⁵ para o detetor de *pre-shower* usado como exemplo, ao ser atingido por elétrons com 181 GeV e píons com 172 GeV [23]. Apenas com este dispositivo bastante simples, um alto fator de rejeição foi prontamente atingido.

A fração de energia perdida logo nas primeiras etapas do desenvolvimento do chuveiro é pequena. Desta forma, se o detetor de *pre-shower* for posicionado diretamente na frente de um sistema de calorimetria, o impacto causado pelo detetor de *pre-shower* na resolução de energia será pequeno [23].

⁵*Minimum Ionizing Particle* (MIP) é uma partícula cuja a taxa média de perda de energia ao interagir com a matéria é mínima. Neste caso, MIP refere-se ao número de partículas produzidas durante o desenvolvimento do chuveiro.

3.3 Sistemas de Calorimetria Utilizados em Colisionadores de Partículas

Dada as características presentes em sistemas de calorimetria, estes dispositivos são fortemente empregados em detetores construídos para analisar eventos produzidos em colisionadores de partícula. Esta seção apresenta os principais sistemas de calorimetria desenvolvidos para os mais recentes experimentos com aceleradores de partículas.

Em experimentos com colisionadores de partículas, a análise da energia é, comumente, feita observando-se a fração de energia projetada perpendicularmente ao feixe de partículas. Esta energia é referida como *energia transversa* (E_T), e é calculada fazendo-se

$$E_T = \frac{E}{\cosh(\eta)} \quad (3.3)$$

onde E é a energia da partícula, e η é a coordenada que define a pseudorapidez da partícula (veja o Apêndice B).

3.3.1 CMS

O detetor CMS é um sistema de detecção multiuso desenvolvido para o acelerador LHC. Seus principais requisitos são:

- Boa identificação de múons e alta resolução para o cálculo do momento destas partículas por uma larga faixa de momento e ângulos.
- Boa resolução para o cálculo do momento de partículas carregadas.
- Boa resolução de energia para partículas eletromagnéticas, alta hermeticidade, com alta taxa de rejeição de π^0 , com bom isolamento de fótons e léptons em alta luminosidade.
- Boa resolução para a identificação de jatos duplos, requerendo um calorímetro hadrônico com grande cobertura geométrica e fina granularidade lateral.

O sistema de calorimetria do CMS é dividido em uma seção eletromagnética e outra hadrônica [5] (vide Figura 3.5).

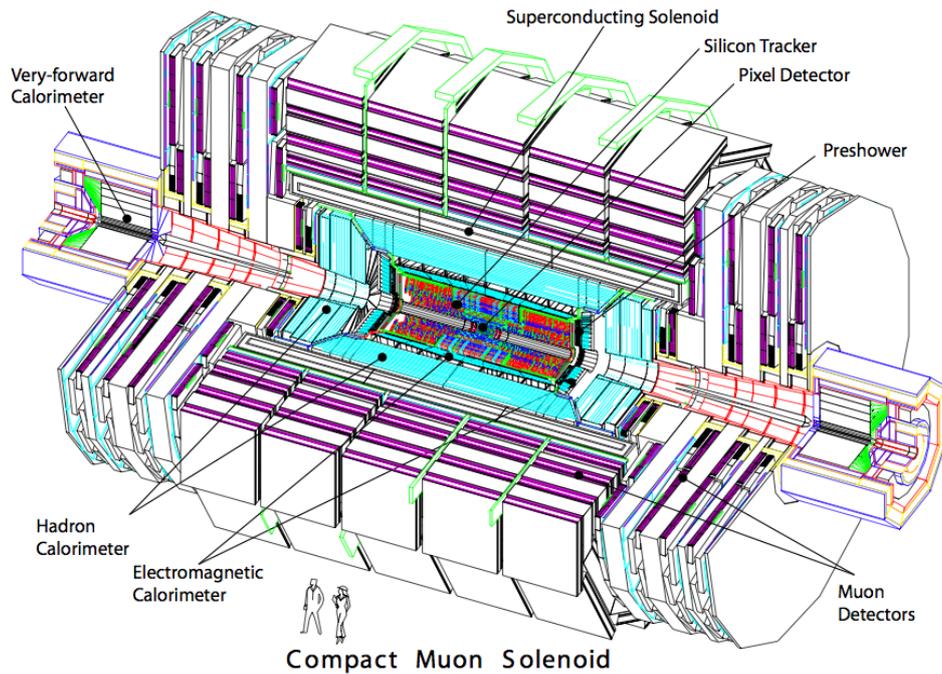


Figura 3.5: Subdetetores do CMS (extraído de [5]).

Seção Eletromagnética

A seção eletromagnética (ECAL) utiliza barras de material cintilante, composto de cristais de tungstato de chumbo (PbWO_4). Este material cintilador tem a vantagem de ser bastante resistente à radiação e ser bastante rápido, com tempo morto da mesma ordem de grandeza que o tempo entre colisões no LHC. Adicionalmente, este material provê boa resolução em energia e fina granularidade, características importantes no ambiente do LHC.

A (ECAL) é dividida em uma parte central (barril), com 2 partes adicionais (uma em cada extremidade, chamadas de *tampa*). Todas as partes possuem granularidades idênticas. O barril cobre a região $|\eta| < 1,479$, sendo composto por 62.200 cristais organizados em uma matriz 170×360 em $\eta \times \phi$ ⁶. Cada barra possui uma seção transversal de aproximadamente $0,0174 \times 0,0174$ em $\eta \times \phi$ ($22 \times 22 \text{ mm}^2$), e profundidade de 230 mm, correspondendo à $25,8 X_0$.

As tampa cobrem a região $1,479 < |\eta| < 3,0$, e cada uma é composta por 7.324 barras. Cada barra possui uma seção transversal de, aproximadamente, $30 \times 30 \text{ mm}^2$ e comprimento de 220 mm ($24,7 X_0$). Um pré-irradiador foi posicionado

⁶ η e ϕ representam um sistema de coordenadas muito usado em calorímetros destinados a experimentos com colisionadores. Este sistema de coordenadas é apresentado no Apêndice B.

à frente das tampas para a identificação de píons neutros na região $1,653 < |\eta| < 2,6$. Este pré-irradiador possui duas camadas sobrepostas: a primeira, composta por chumbo, com $2 X_0$ de profundidade, inicializa chuveiros eletromagnéticos de elétrons ou fótons incidentes. A segunda camada, composta por tiras de silício e com $1 X_0$ de profundidade, mede a energia depositada e o perfil lateral do chuveiro. A profundidade total do pré-irradiador é de 20 cm.

Seção Hadrônica

O calorímetro hadrônico (HCAL) envolve o calorímetro eletromagnético, cobrindo, também, a região $|\eta| < 3$. Tal como o ECAL, o calorímetro hadrônico utiliza cintiladores como material ativo. Adicionalmente, este calorímetro também é dividido em barril e tampa.

O barril cobre a região até $|\eta| < 1,3$. O material passivo utilizado é composto por uma combinação de aço, cobre e zinco. Esta combinação provê uma profundidade total variável e crescente de $5,82 \lambda_{int}$ em $\eta = 0$ até $10,6 \lambda_{int}$ em $|\eta| = 1,3$. O calorímetro eletromagnético acrescenta, aproximadamente, $1,1 \lambda_{int}$ de material. O barril possui uma granularidade de $(\Delta\eta \times \Delta\phi) = (0,087 \times 0,087)$.

As tampas do HCAL cobrem a região $1,3 < |\eta| < 3,0$. Por estarem muito próximas de um imã com 4 teslas, o material absorvedor deste calorímetro precisa ser de material não-magnético. Adicionalmente, precisa ter uma profundidade suficiente para conter cascatas hadrônicas. Desta forma, foi adotado um composto formado por cobre e zinco. As tampas possuem granularidade de $(\Delta\eta \times \Delta\phi) = (0,087 \times 0,087)$ para $|\eta| < 1,6$ e $(\Delta\eta \times \Delta\phi) = (0,17 \times 0,17)$ para $|\eta| \geq 1,6$.

3.3.2 ZEUS

O detetor ZEUS [24] foi desenvolvido para analisar as colisões elétron-próton ocorridas no colisionador HERA [25]. O objetivo do detetor ZEUS é determinar com alta precisão a energia, direção e natureza de partículas isoladas e jatos criados durante as colisões promovidas pelo HERA.

O coração do ZEUS é o seu calorímetro. Este calorímetro cobre aproximadamente 99,8 % de ângulo sólido completo e proporciona respostas iguais para elétrons e hádrons para toda a sua faixa de energia. A granularidade deste calorímetro per-

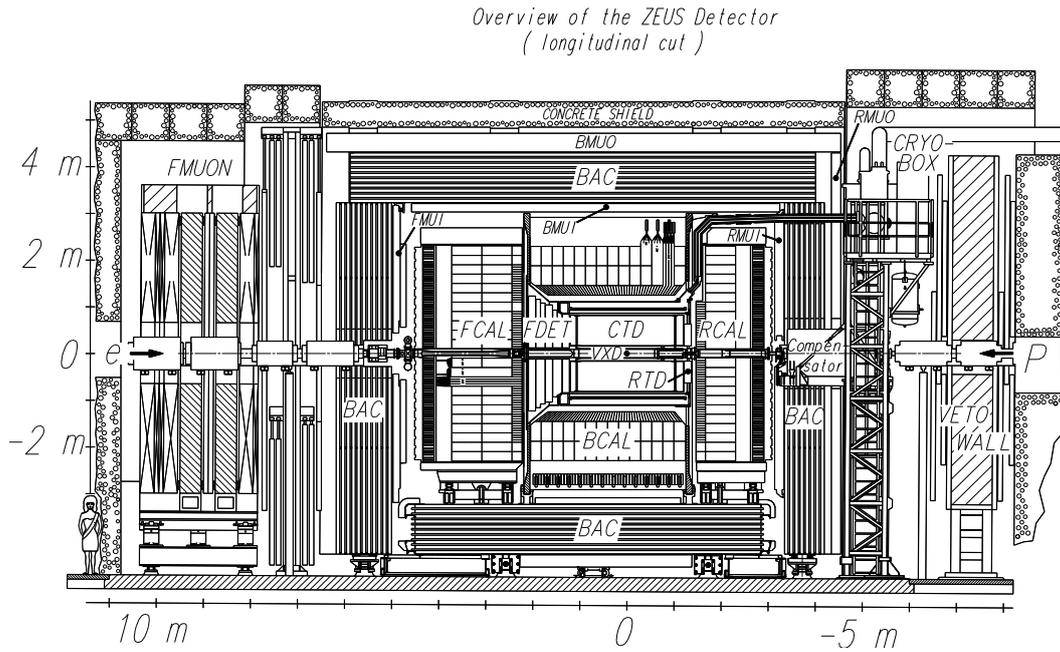


Figura 3.6: Visão longitudinal esquemática do detetor ZEUS (extraído de [24]).

mite a distinção entre elétrons e hádrons utilizando seus perfis de deposição de energia. e uma resolução temporal de 1 ns.

O detetor ZEUS apresenta-se de maneira bastante diferenciada de outros detetores utilizados em colisionadores $p\bar{p}$ ou e^+e^- , uma vez que não é simétrico em relação ao plano perpendicular ao eixo do feixe no ponto de colisão. Esta diferença ocorre devido à cinemática das colisões no HERA.

Devido à grande diferença de momentos entre elétrons e prótons, o centro de massa das colisões move-se na direção dos prótons (*forward direction*). Conseqüentemente, os resquícios das colisões carregam mais momento nesta direção. A Figura 3.6 apresenta a visão longitudinal da seção transversal do ZEUS, evidenciando a sua assimetria. A direção dos feixes de elétrons e prótons está assinalada na mesma figura. O ponto $x = 0$ m é o ponto onde as colisões ocorrem.

O sistema de calorimetria é dividido em 3 partes:

- O calorímetro frontal (*forward calorimeter* - FCAL) cobre os ângulos polares (medidos em relação à direção de propagação dos prótons) entre $2,2^\circ < \theta < 39,9^\circ$.
- O barril (*barrel calorimeter* - BCAL), na região $36,7^\circ < \theta < 129,1^\circ$.
- A região traseira (*rear calorimeter* - RCAL), na região $128,1^\circ < \theta < 176,5^\circ$.

O BCAL forma uma estrutura cilíndrica ao redor do eixo do feixe, possuindo $5 \lambda_{int}$. O FCAL e RCAL consistem de módulos retangulares que formam duas paredes perpendicular ao eixo do feixe. A profundidade é de $7 \lambda_{int}$ para o FCAL, e $4 \lambda_{int}$ para o RCAL. A diferença em profundidades reflete a grande diferença na energia de partículas detectadas nestas duas seções do sistema de calorimetria.

Todos os calorímetros consistem em placas absorvedoras de urânio empobrecido (^{238}U). Estas placas são intercaladas por telhas de plástico cintilante. As camadas de absorção são posicionadas perpendicular à linha do feixe no FCAL e RCAL e paralelo a este no BCAL.

Longitudinalmente, o FCAL e BCAL são subdivididos em 3 segmentos. Uma seção eletromagnética e duas hadrônicas. o RCAL possui apenas uma seção hadrônica. Em todos os calorímetros, a seção EM tem aproximadamente $25 X_0$ ($\approx 1 \lambda_{int}$) de profundidade. As seção hadrônica do FCAL possui $6,2 \lambda_{int}$ de profundidade, contra $4,2 \lambda_{int}$ para o BCAL e $3,1 \lambda_{int}$ para o RCAL.

3.3.3 ATLAS

O sistema de calorimetria do ATLAS (apresentado na Figura 3.7) foi construído com diversas tecnologias, visando otimizar a detecção e a medida de energia para uma variedade de partículas, para uma larga faixa de energia. Conforme dito anteriormente, a calorimetria deste detetor é dividida em 2 partes: eletromagnética e hadrônica.

Calorímetro Eletromagnético

A parte mais interna do sistema de calorimetria do ATLAS é composta pelo calorímetro eletromagnético (EM). Este calorímetro é baseado em absorvedores de chumbo e utiliza Argônio líquido como material ativo. O calorímetro eletromagnético cobre a região até $|\eta| < 3,2$. Para prover uma cobertura completa em ϕ , os absorvedores de chumbo são dobrados em formato de acordeão. As placas de chumbo são cobertas por finos eletrodos de cobre. Adicionalmente, estas placas estão imersas em um tanque de Argônio líquido e sujeitas a um forte campo elétrico. Quando um chuvaire de elétrons, produzido dentro do chumbo, chega ao Argônio, elétrons são arrancados dos átomos de Argônio [15]. O campo elétrico, então, faz

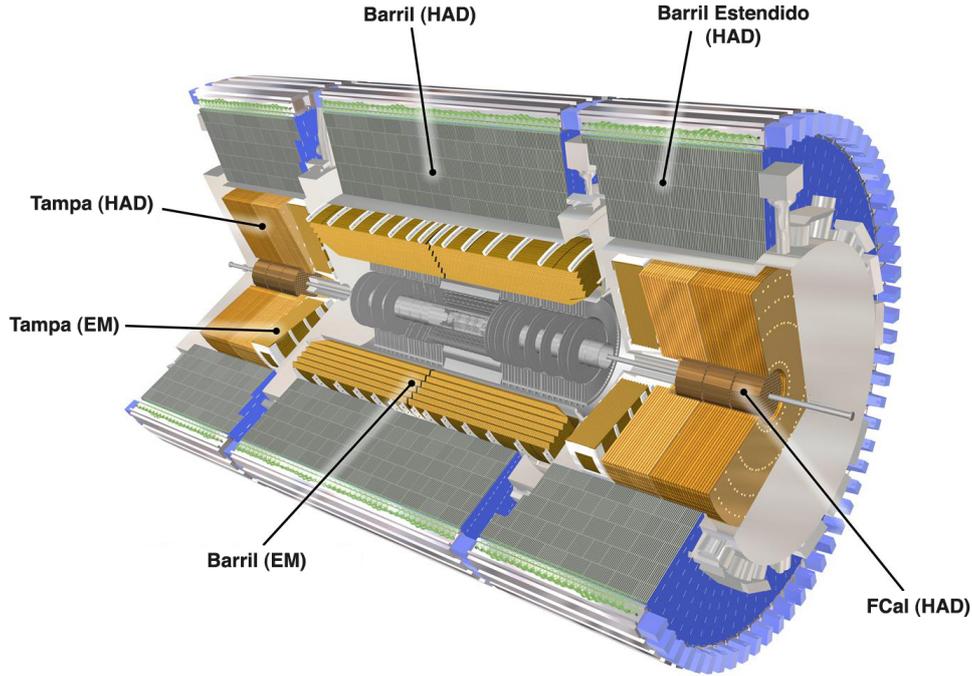


Figura 3.7: Conjunto de calorímetros do detector ATLAS (extraído de [10]).

com que os elétrons livres migrem para o lado positivo do campo (muito mais rapidamente do que os cátions, que, muito mais pesados, migram para o lado negativo), gerando uma corrente elétrica em um circuito externo conectado ao calorímetro. Quanto maior a energia da partícula incidente, maior o número de elétrons produzidos no chuvaire produzido, e, conseqüentemente, maior a corrente gerada.

Ao segmentarem-se (no plano $\eta \times \phi$) os eletrodos na superfície das placas em formato de acordeão, a coleção de íons produzidos no Argônio líquido pode ser espacialmente localizada. Desta forma, obtêm-se células, numa posição $\eta \times \phi$, com um valor de energia associado. Adicionalmente, estas células são organizadas em três camadas sobrepostas em y (vide a Figura 3.8). Em cada camada, as células apresentam geometrias distintas, dependendo dos requisitos de discriminação ou medição de energia das partículas incidentes.

É apresentada na Figura 3.8 a segmentação de cada camada deste calorímetro. A segunda camada (EM2) é a mais profunda, de forma que a maior parte da energia de um elétron ou fóton incidente fica retida nesta camada. *Clusters* de células (para análise pelo sistema de filtragem, por exemplo) são comumente definidos usando esta camada como referência. Por exemplo, um *cluster* 3×7 é uma região do detector definida por 3 células em η e 7 células em ϕ , considerando a largura ($\Delta\eta \times \Delta\phi$)

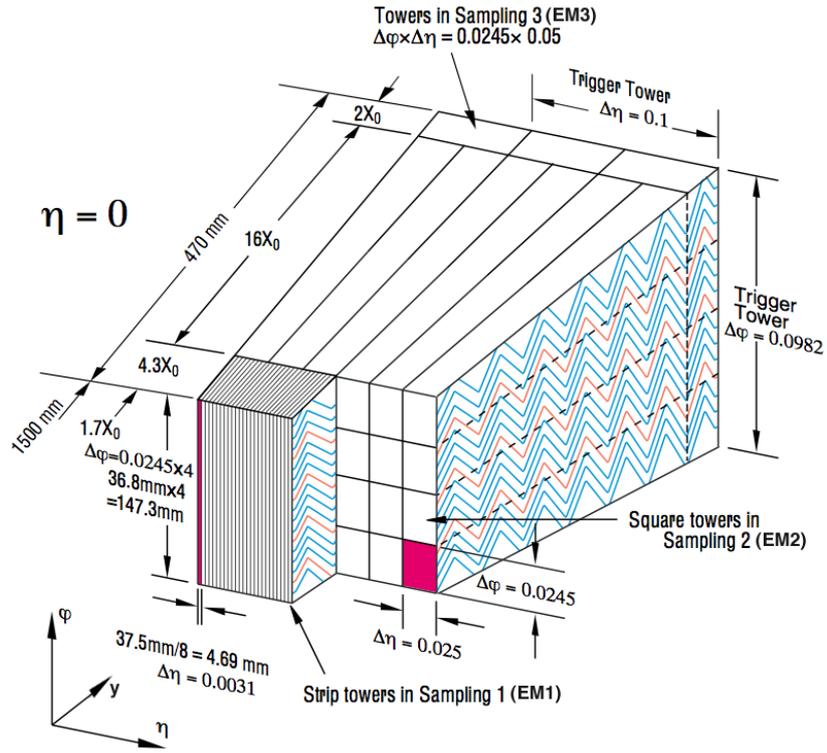


Figura 3.8: Estrutura de segmentação para cada camada do calorímetro eletromagnético (extraído de [26]).

de uma célula da segunda camada eletromagnética. A primeira camada eletromagnética (EM1) é altamente segmentada em η , visando permitir a análise da dispersão lateral do chuveiro ao longo desta coordenada. A terceira camada (EM3) provê retenção adicional para partículas eletromagnéticas muito energéticas. Para compensar a perda de energia no material morto existente na frente do calorímetro eletromagnético, um pré-irradiador (PS) é posicionado na frente deste calorímetro, cobrindo a região $|\eta| < 1,8$. Como exemplo, a Figura 3.9 apresenta a interação de um elétron com as 4 camadas que compõem o calorímetro eletromagnético. Nesta figura, percebe-se como o perfil de deposição de energia varia de acordo com a granularidade e a profundidade de cada camada.

O calorímetro eletromagnético é dividido em duas partes: o barril, cobrindo a parte mais central do ATLAS, e a tampa, para cobrir valores mais elevados de η ($1,3 \leq |\eta| \leq 2,5$). É apresentada, na Figura 3.10, a visão longitudinal de um quadrante do calorímetro eletromagnético, mostrando o posicionamento do barril e da tampa.

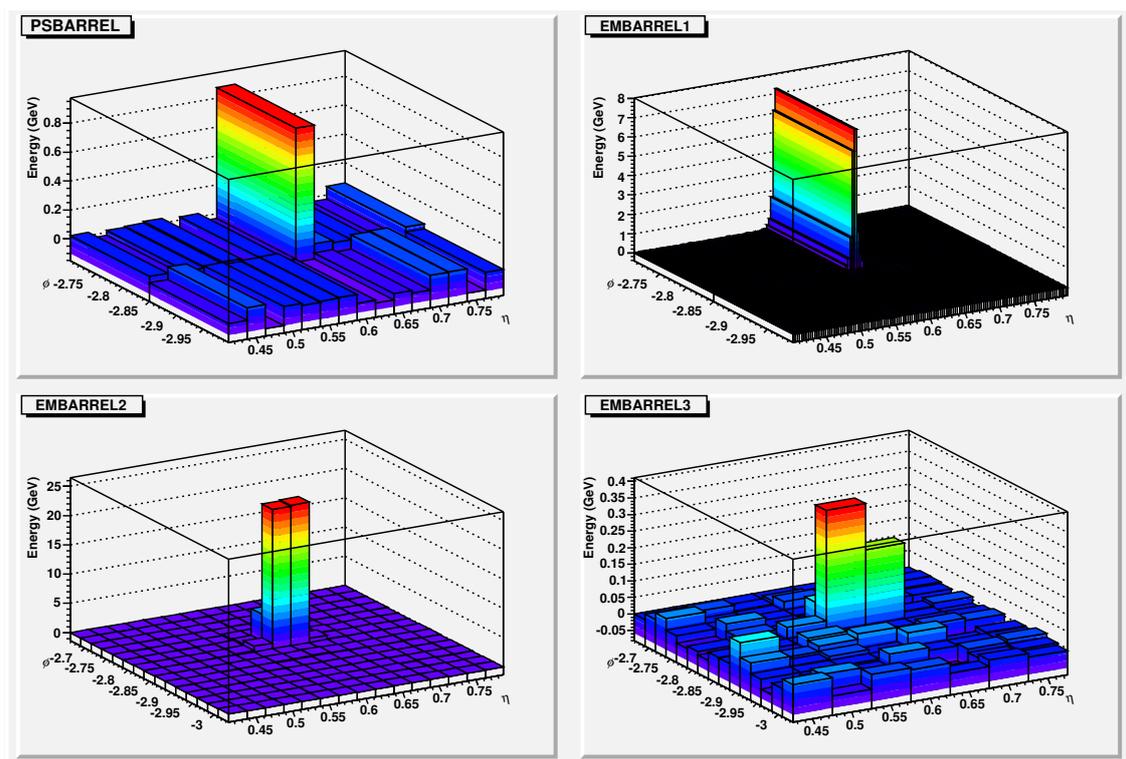


Figura 3.9: Exemplo da interação (simulação) de um elétron com 70 GeV de energia transversa com todas as 4 camadas do calorímetro eletromagnético do barril.

Tabela 3.1: Granularidade de cada camada do calorímetro eletromagnético.

Camada	Peça	$\eta_{\text{início}}$	η_{fim}	$\Delta\eta \times \Delta\phi$	$N_\eta \times N_\phi$
<i>Pre-sampler</i>	Barril	0	1,5	$0,025 \times 0,1$	4×1
	Tampa	1,5	1,8	$0,025 \times 0,1$	4×1
Camada 1	Barril	0	1,4	$0,003125 \times 0,1$	32×1
		1,4	1,475	$0,025 \times 0,025$	4×4
	Tampa	1,375	1,5	$0,025 \times 0,1$	1×4
		1,5	1,8	$0,003125 \times 0,1$	32×1
		1,8	2,0	$0,004167 \times 0,1$	24×1
		2,0	2,4	$0,00625 \times 0,1$	16×1
		2,4	2,5	$0,025 \times 0,1$	4×1
2,5	3,2	$0,1 \times 0,1$	1×1		
Camada 2	Barril	0	1,4	$0,025 \times 0,025$	4×4
		1,4	1,475	$0,075 \times 0,025$	1×4
	Tampa	1,375	2,5	$0,025 \times 0,025$	4×4
		2,5	3,2	$0,1 \times 0,1$	1×1
Camada 3	Barril	0	1,35	$0,05 \times 0,025$	2×4
	Tampa	1,5	2,5	$0,05 \times 0,025$	2×4

A Tabela 3.1 resume a segmentação de cada camada do calorímetro eletromagnético do ATLAS. Observa-se que a granularidade nas tampas é menos fina. Isto destina-se à redução de custos, visto ser mais baixa a probabilidade de eventos de interesse nestas regiões. Nesta tabela, $N_\eta \times N_\phi$ representam, para uma dada parte do calorímetro eletromagnético, o número de células necessárias para compor uma janela de $0,1 \times 0,1$ em $\eta \times \phi$, o que é usado no sistema de filtragem.

Embora o calorímetro eletromagnético cubra toda a região $-\pi < \phi \leq +\pi$, o mesmo não ocorre ao longo de η . Existem pequenas regiões com fendas (*crack regions*) onde a resposta do detetor é deteriorada em relação ao resto deste calorímetro, devido a presença de material morto nestas regiões [26]. Estas fendas são as regiões de transição entre partes mecanicamente independentes do calorímetro eletromagnético, a saber:

1. A região de transição entre as duas metades do barril em $|\eta| < 0,015$.
2. A região de transição entre o barril e a tampa em $|\eta| \approx 1,45$.
3. A região de transição entre a parte externa e interna da tampa em $|\eta| = 2,5$.

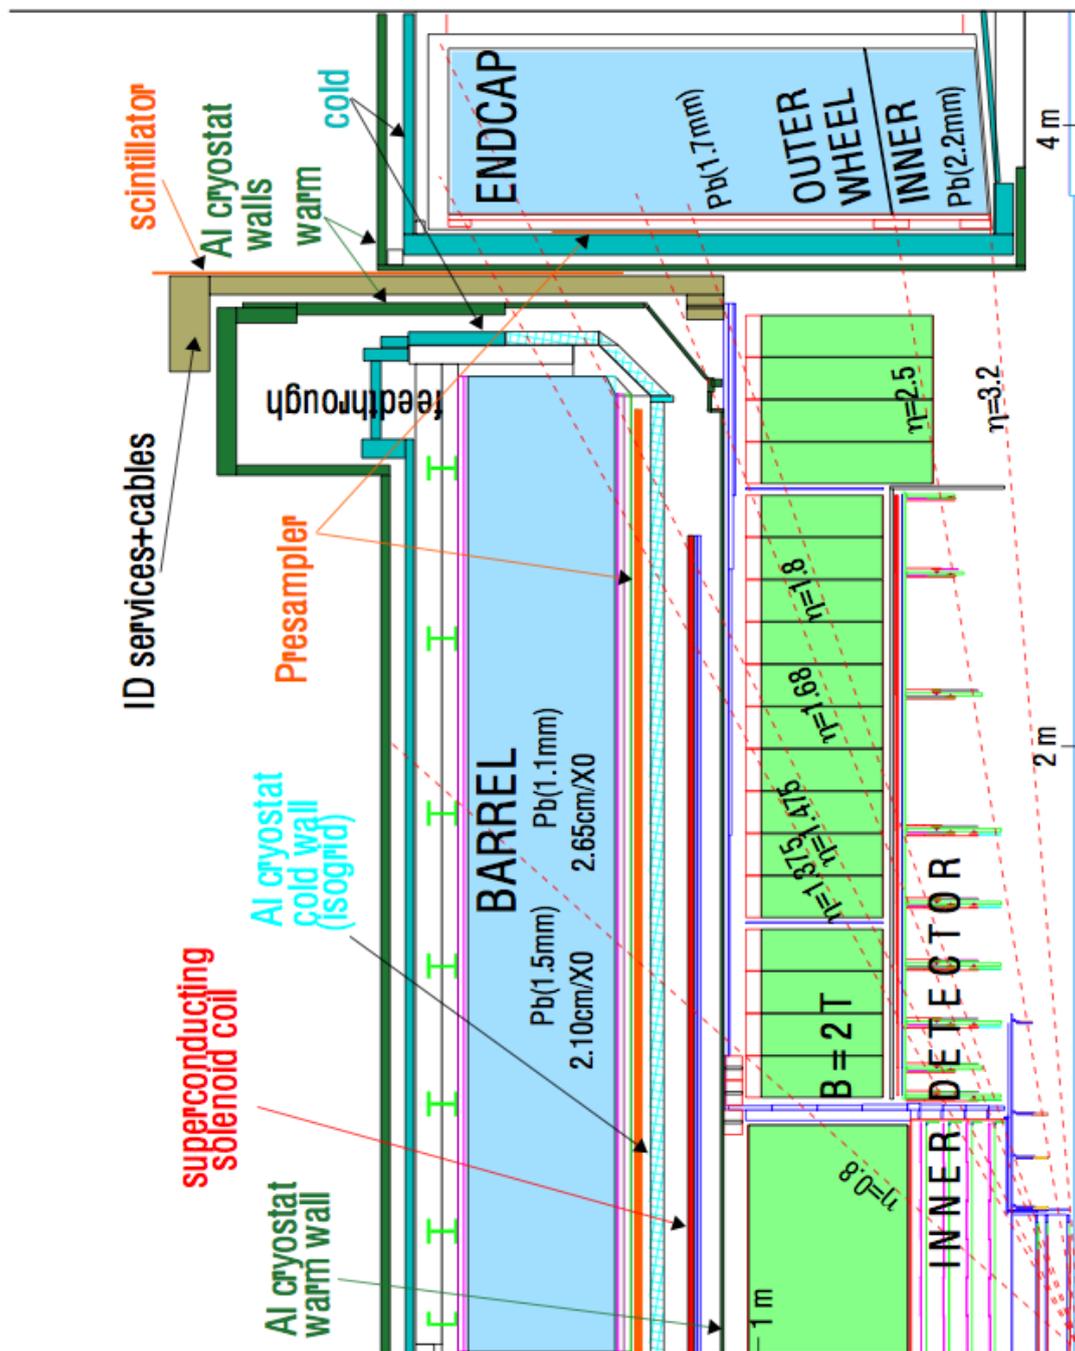


Figura 3.10: Visão longitudinal de um quadrante do calorímetro eletromagnético (extraído de [26]).

As duas primeiras fendas são as mais importantes, visto que ocorrem dentro da zona de eventos onde se necessita de maior precisão ($\eta < 2,5$). A segunda fenda ($\eta \approx 1,45$) é a mais problemática, visto que é a mais larga. Observa-se, na Figura 3.10, esta região de transição. Parte da energia perdida nesta região é recuperada pelo *pre-sampler*. Entretanto, na região $1,45 < |\eta| < 1,55$, a energia perdida no material morto posicionado na frente do calorímetro é muito grande para ser eficientemente recuperada apenas pelo *pre-sampler*. Nesta região, um cintilador foi introduzido para auxiliar o trabalho do *pre-sampler*, visto que este cintilador está posicionado no meio da região do material morto, cobrindo a região $1,0 < |\eta| < 1,6$.

Calorímetro Hadrônico

Este dispositivo mede a energia dos hádrons que o atingem, incluindo prótons, nêutrons, píons e káons (elétrons e fótons foram absorvidos na seção eletromagnética). O calorímetro hadrônico utiliza placas de ferro como material absorvedor e placas cintilantes como material ativo, ambas no formato de telhas. Entretanto, uma vez que os hádrons podem iniciar seus chuveiros no calorímetro eletromagnético, os sinais obtido pelos dois calorímetros precisam ser combinados para se obter a estimativa da energia hadrônica total.

Tal como o calorímetro eletromagnético, o calorímetro hadrônico também é segmentado, sendo dividido em 3 camadas. É apresentado, na Figura 3.11, o esquemático da organização das células e das camadas do calorímetro hadrônico. Adicionalmente, observa-se na Tabela 3.2 a granularidade de cada parte da seção hadrônica. Novamente, $N_\eta \times N_\phi$ representam, para uma dada parte deste calorímetro, o número de células necessárias para compor uma janela de $0,1 \times 0,1$ em $\eta \times \phi$. É apresentado, na Figura 3.12, o perfil de deposição de energia para um jato, com 50 GeV de energia transversa, ao interagir com as 3 camadas do calorímetro hadrônico. Nota-se, em comparação ao calorímetro eletromagnético, que as células do calorímetro hadrônico são maiores. Isto se deve ao fato dos chuveiros hadrônicos serem consideravelmente mais largos do que chuveiros eletromagnéticos, de tal forma que a dimensão das células deste calorímetro devem ser compatíveis com o perfil lateral do chuveiro hadrônico. Logo, esta redução de granularidade permite a redução de custos de desenvolvimento, ao mesmo tempo que é adequada

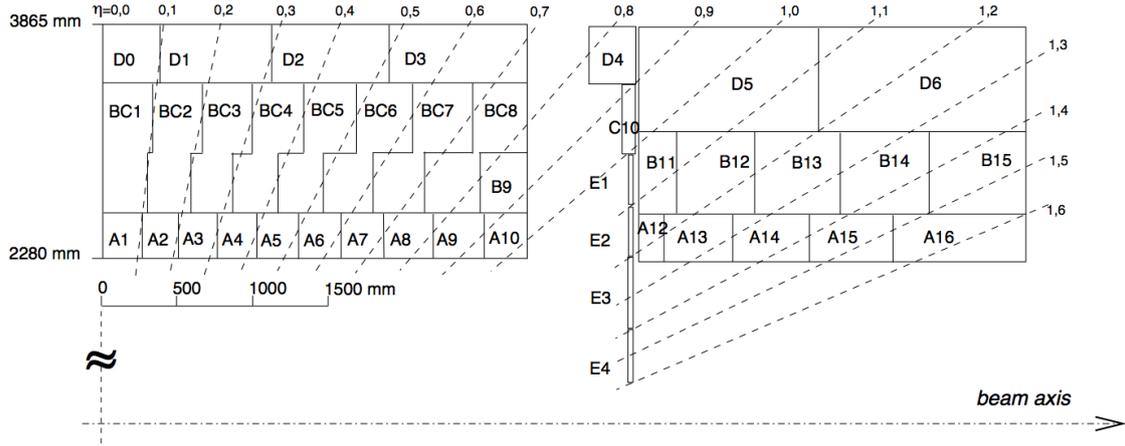


Figura 3.11: Distribuição das células para o barril e o barril estendido do calorímetro hadrônico (extraído de [11]).

Tabela 3.2: Granularidade de cada camada do calorímetro hadrônico.

Camada	Peça	$\eta_{\text{início}}$	η_{fim}	$\Delta\eta \times \Delta\phi$	$N_{\eta} \times N_{\phi}$
Camadas 1 e 2	Barril (TileCal)	0	1,0	$0,1 \times 0,1$	2×2
	Barril Ext. (TileCal)	0,8	1,7	$0,1 \times 0,1$	2×2
	Tampa (LAr)	1,5	2,5	$0,1 \times 0,1$	2×2
		2,5	3,2	$0,2 \times 0,2$	1×1
Camada 3	Barril (TileCal)	0	1,0	$0,2 \times 0,1$	1×2
	Barril Ext. (TileCal)	0,8	1,7	$0,2 \times 0,1$	1×2
	Tampa (LAr)	1,5	2,5	$0,1 \times 0,1$	2×2
		2,5	3,2	$0,2 \times 0,2$	1×1

para a análise de hádrons [27].

A energia total emanada do ponto de colisão é menos intensa para grandes angulações (próximo a 90 graus), e mais intensa a ângulos menores em relação ao feixe. Devido ao fato que as telhas cintilantes podem se danificar se expostas à radiação, a calorimetria hadrônica, para ângulos entre 5 e 25 graus, é fornecida por um dispositivo de Argônio líquido muito similar ao utilizado no calorímetro eletromagnético. As principais diferenças são que as pastilhas de chumbo são substituídas por pastilhas de cobre, que são mais apropriadas para o chuveiro hadrônico.

Para permitir a cobertura angular total, é necessário estender o calorímetro para que este detecte eventos a ângulos tão pequenos quanto 1 grau relativo aos feixes. Devido ao ambiente extremamente radioativo na região angular entre 1 e 5 graus,

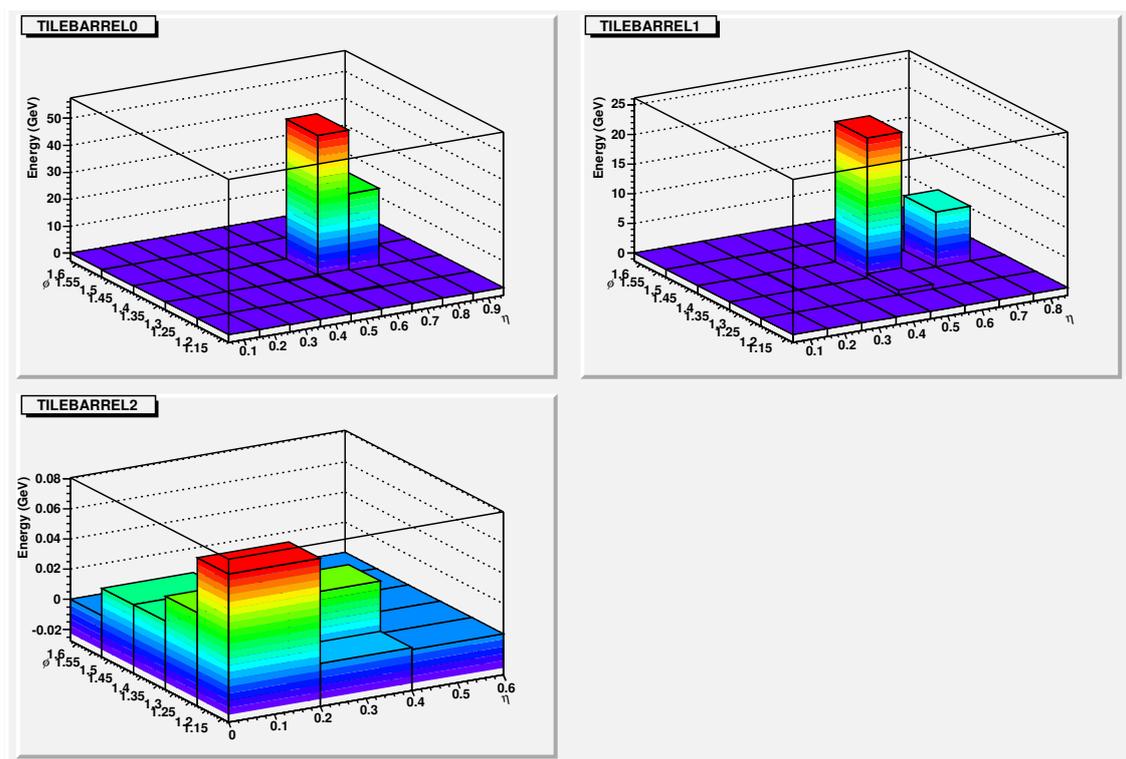


Figura 3.12: Exemplo da interação de um jato com 50 GeV de energia transversa com todas as 3 camadas do calorímetro hadrônico do barril.

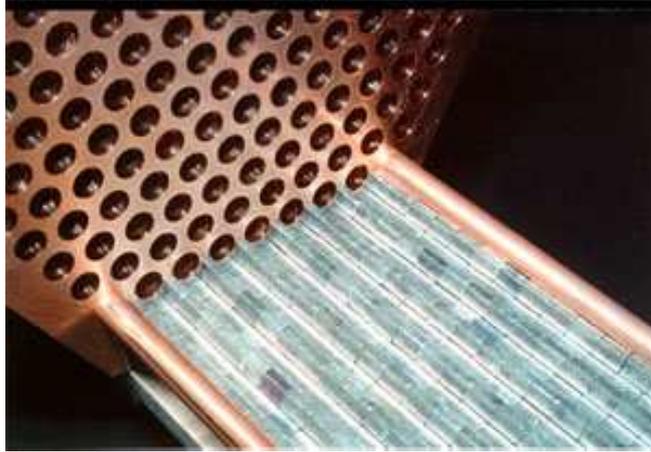


Figura 3.13: Ilustração das barras metálicas sendo inseridas nos tubos da calorímetro de Argônio líquido do calorímetro hadrônico (extraído de [12]).

a calorimetria precisa ser desenvolvida com cuidados especiais. Nesta região, o calorímetro de Argônio líquido tem suas pastilhas metálicas substituídas por uma matriz metálica que contém tubos ocultos embutidos, de diâmetro interno de 5 mm. Barras metálicas de 4,5 mm são posicionadas dentro destes tubos (vide Figura 3.13), e o Argônio líquido preenche o pequeno espaço existente entre as barras e os tubos que as contém. A tensão aplicada entre uma barra e um tubo produz o campo elétrico necessário para fazer os elétrons migrarem dentro do Argônio líquido, após a ionização gerada pelo chuveiro hadrônico. Este calorímetro recebe o nome de *Forward Calorimeter* (FCal), e destina-se a estudos muito específicos, não abordados neste trabalho.

Capítulo 4

Sistemas de Filtragem

A maioria das reações físicas de interesse estudadas nos modernos colisionadores de partículas ocorrem com frequência bastante reduzida. Por exemplo, o LHC produzirá uma taxa de eventos de aproximadamente 1 GHz (aproximadamente 25 eventos por colisão). A Figura 4.1 apresenta a taxa esperada de eventos durante a operação nominal do LHC. Processos relevantes, como por exemplo $h \rightarrow \gamma\gamma$, ocorrerão com uma frequência de milésimos de Hz [28]. Por outro lado, jatos estarão sendo produzidos com uma frequência da ordem de centenas de kHz, e representam um forte ruído de fundo para muitos processos físicos.

O problema da alta taxa de eventos, somado à raridade com que os canais físicos ocorrem é um problema compartilhado por todos os experimentos modernos envolvendo colisionadores de partícula. A Tabela 4.1 apresenta, para os principais colisionadores da atualidade, a luminosidade, o volume de informação produzido por colisão, a taxa de colisões produzidas por estes aceleradores, e a taxa esperada de colisões que produzirão eventos relevantes. Como se observa, enquanto a taxa de colisões está na ordem de MHz, a frequência esperada de colisões relevantes está na ordem de Hz, mostrando que a maior parte da informação produzida por estes aceleradores é composta por ruído de fundo [29]. Conseqüentemente, os detetores desenvolvidos para estes colisionadores precisam ser dotados de um sofisticado sistema de filtragem, responsável por descartar eventos sem interesse para o experimento. Este sistema de filtragem precisa ser cuidadosamente desenvolvido, de forma a atingir uma alta taxa de rejeição de ruído de fundo, ao mesmo tempo que possui uma alta eficiência no que tange a seleção dos raros canais físicos importantes.

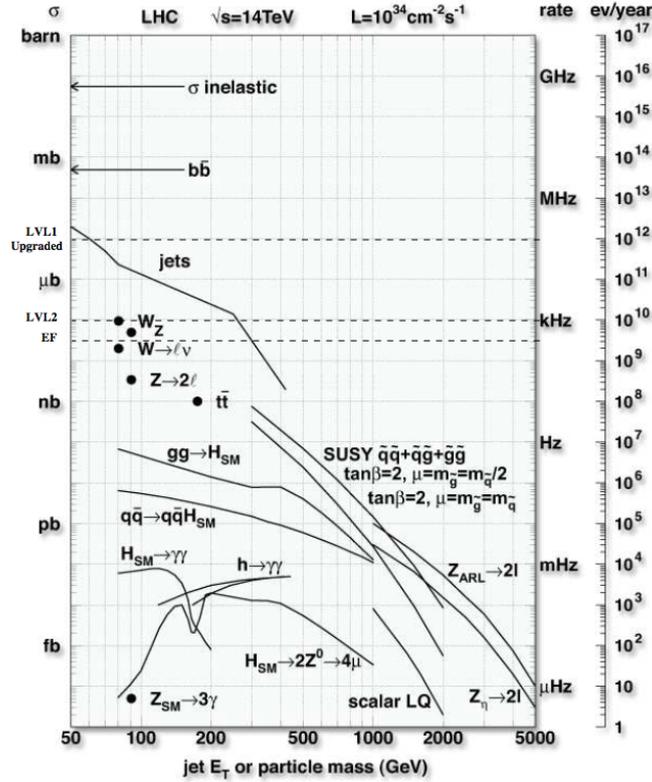


Figura 4.1: Taxa de eventos esperada durante a operação nominal do LHC (extraído de [28]).

Além da taxa de colisões, a granularidade dos detetores envolvidos na aquisição dos eventos produzidos colabora de forma crucial com o volume de informação gerado. O número de detetores empregados na análise das colisões, junto com a granularidade de cada um deles, fornecerá a quantidade de informação produzida a cada colisão (vide Tabela 4.1). Este número, multiplicado pela taxa de colisões, dará o volume de informação esperado nos canais de leitura do sistema de detecção. Por exemplo, o acelerador HERA, com seus detetores, produzirá, aproximadamente, 1 TBytes/seg de informação. Consequentemente, o volume de informação possui um papel fundamental na escolha da melhor abordagem para um sistema de filtragem. Em situações onde o volume de informação produzida é baixo, pode-se considerar uma abordagem *offline* para a filtragem dos eventos. Nesta abordagem, como o fator tempo não importa, análises mais profundas podem ser realizadas em cada evento. Por outro lado, em situações onde o volume de informação produzida é muito elevado, e o evento de interesse ocorre a frequências muito reduzidas, o armazenamento de toda a informação, para posterior análise *offline* torna-se proibitivo.

Tabela 4.1: Luminosidade, frequência de colisões e volume de informação produzido para os principais colisionadores da atualidade.

Acelerador	Luminosidade ($10^{30} \text{ cm}^{-2} \text{ s}^{-1}$)	Volume de Informação por Colisão (MBytes)	Freq. de Colisões (MHz)	Freq. de Colisões Relevantes (Hz)
HERA	14	0,1	10,417	2-4
TeV	200	0,25	2,525	50
LHC	10.000	1,5	40	100

Nestas situações, o processo de filtragem deve ser *online*. Nesta última abordagem, o tempo de processamento tem um papel fundamental, de forma que a quantidade de tempo disponível para cada evento determinará a profundidade da análise realizada no mesmo, e, conseqüentemente, a eficiência de filtragem obtida com esta implementação.

4.1 Sistemas de Filtragem *Online*

Em sistemas de filtragem *online*, normalmente aborda-se um sistema hierárquico de análise, onde os níveis superiores validam a decisão dos níveis inferiores. Tipicamente (veja a Figura 4.2), a hierarquia de análise de um sistema de filtragem *online* é desenvolvida de forma que os níveis mais baixos apliquem cortes baseados em critérios de análise mais simples, enquanto que níveis mais elevados implementam critérios de seleção mais complexos, uma vez que dispõem de um tempo maior para análise de cada evento. Entretanto, como os níveis mais altos operam sobre um subconjunto dos eventos que não foram rejeitados pelos níveis inferiores, estes sistemas de filtragem hierárquicos não podem desfazer a rejeição aplicada por um nível mais baixo.

No geral, existem vários parâmetros que caracterizam um sistema de filtragem *online*. O tempo de latência e o tamanho dos *buffers* de memória estão diretamente correlacionados, de tal forma que o tamanho do *buffer* de entrada possui um papel fundamental na determinação da latência máxima, taxa e tamanho dos eventos. Isto é particularmente relevante para o primeiro nível de filtragem, onde a quantidade de informação a ser analisada, por evento, é normalmente pequena, mas os eventos são

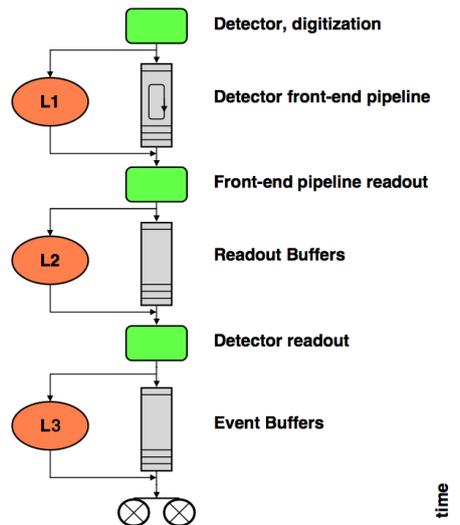


Figura 4.2: Visão geral da hierarquia de um sistema de filtragem.

obtidos a taxas muito elevadas. Em geral, níveis mais altos de filtragem possuem um tempo maior de análise, pois a quantidade de dados brutos e a taxa de eventos reduz-se, enquanto, por outro lado, a quantidade de informação considerada sobre os eventos restantes aumenta.

Os primeiros níveis de filtragem frequentemente possuem um baixo tempo de latência (da ordem de μs) [30] e são implementados tanto como *sistemas de filtragem integrados*, sendo parte de um sistema de leitura de informação dos detetores, ou como *sistemas sistólicos*, que implementam códigos mais complexos implementados em FPGA. Estes últimos também podem envolver processadores digitais de sinais (*Digital Signal Processors* - DSP) [31] para cálculos aritméticos mais complexos.

Sistemas de filtragem de mais alto nível, tipicamente envolvem processadores de uso geral, do tipo PC, conectados em rede de alta velocidade, e operando com latências mais altas e taxa de eventos mais baixas, tornando possível a execução de algoritmos mais complexos.

4.1.1 Sistemas de Filtragem em *Hardware*

Atualmente, o grande poder de processamento oferecido por dispositivos de *hardware* de baixa programabilidade, tais como ASIC (*Application Specific Integrated Circuit*) [32] e FPGA [33], torna a utilização destes bastante atraente em sistemas de filtragem em *hardware*. Estes dispositivos permitem a codificação de algoritmos

relativamente complexos em silício para atingir grandes níveis de rejeição de eventos. Atualmente, quase todos os experimentos em física de altas energias (ATLAS, CMS, CDF [34] e DØ [35], por exemplo) empregam estes componentes no primeiro nível de seus sistemas de filtragem.

Existem muitas características comuns entre os sistemas de filtragem em *hardware* dos experimentos modernos [29]. Todos estes experimentos realizam o armazenamento dos eventos em memórias do tipo *pipeline*, cujo tamanho depende das necessidades do experimento. A utilização destas memórias aumenta o tempo disponível para o sistema de filtragem em *hardware* prover sua decisão, ao custo de garantir que haverá memória suficiente para armazenar novos eventos, enquanto a decisão é tomada para um dado evento.

Em geral, o primeiro nível de filtragem emprega todos os detetores disponíveis (calorimetria, detetores de traços e câmara de múons). O ATLAS e o CMS são exceção a esta regra, visto que nenhum dos dois está apto a analisar o traço de partículas (algoritmos que possuem custo computacional elevado), uma vez que o volume de informação destes dois detetores é muito grande. Consequentemente, ATLAS e CMS realizam o primeiro nível de filtragem empregando apenas a informação (com granularidade reduzida) de seus sistemas de calorimetria e câmara de múons.

Normalmente, sistemas de filtragem em *hardware* empregam algoritmos que realizam análises simples sobre os eventos adquiridos. Por exemplo, a detecção de elétrons no primeiro nível do CMS [5] emprega uma janela de tamanho 3×3 torres de *trigger*¹ em $\eta \times \phi$. Esta janela é deslizada pelo calorímetro eletromagnético, procurando por picos de energia correspondentes ao centro de eventos incidentes. Quando um pico de energia é encontrado, a identificação de elétrons é feita através da aplicação de cortes lineares em grandezas que analisam a razão entre a deposição de energia na seção hadrônica e eletromagnética, bem como o perfil lateral do chuveiro eletromagnético, analisando-se a energia amostrada pelas células imediatamente ao redor da célula quente.

Uma exceção é o segundo nível de filtragem do experimento H1 [36], do acelerador

¹Uma torre de trigger (*trigger tower*) é o sinal obtido somando-se as células contidas numa região em $\eta \times \phi$ de 5×5 células. Cada torre é composta por 5 tiras de tamanho 1×5 células em $\eta \times \phi$.

HERA. Este sistema utiliza redes neurais artificiais implementadas em *hardware* [37]. Neste nível, o tempo de latência está limitado a $20 \mu s$, de forma a lidar com a taxa de entrada de 1-2 kHz proveniente do L1 [38].

As redes neurais são implementadas por *chips* contendo uma cadeia de 64 processadores operando em modo SIMD (*Single Instruction on Multiple Data Stream*) [31], e aritmética computacional em ponto fixo [39]. Cada rede é otimizada para um canal físico específico. Como entrada, cada rede recebe a informação da trajetória das partículas, e a quantidade de energia depositada em cada seção do calorímetro do H1. Cada rede neural possui função de ativação sigmoideal na camada escondida, implementada através de *Lookup Table* (LUT), e treinada por método supervisionado para aprovar (valor de saída +1) ou reprovar (valor de saída 0) cada evento. A rede final é capaz de produzir uma resposta em $8 \mu s$ sob um *clock* de 20,8 MHz. O mesmo resultado, caso implementado em processadores de uso geral, iria requerer um processador com *clock* da ordem de $O(10)$ GHz [40].

4.1.2 Sistemas de Filtragem de Alto Nível

Sistemas integrados e FPGA podem ser altamente customizados. Entretanto, o tempo de desenvolvimento neste tipo de tecnologia costuma ser longo, o que força a escolha da tecnologia a ser adotada com muita antecedência, inibindo a adoção de novas tecnologias que surjam ao longo do desenvolvimento do sistema de filtragem. Em contrapartida, o baixo custo, velocidade de evolução e rápido ciclo de desenvolvimento obtido quando se utilizam computadores de uso geral tornam o uso deste tipo de processador bastante atraente. Adicionalmente, o desenvolvimento de algoritmos de filtragem não necessitam de infraestrutura especial. Contudo, para que PCs possam ser utilizados para filtragem *online* em ambientes com alta taxa de eventos, torna-se necessário resolver o problema do grande volume de informação a ser trafegada pelo sistema de filtragem de alto nível.

O tráfego de dados, bem como a comunicação entre os componentes do sistema de filtragem de alto nível são orquestrados por um sistema comumente referido como Sistema de Controle e Aquisição de Dados (*Data Acquisition and Control* - DAQ). O DAQ é composto por um conjunto de componentes que executam algoritmos de baixo custo computacional encarregados de definir e garantir o correto fluxo

de informação dentro do sistema de filtragem de alto nível, bem como permitir a comunicação entre cada módulo através de uma interface genérica. Isto permite que uma sequência de análises possa ser configurada de acordo com a disponibilidade de dados (reais, simulados, etc.) e nós de processamento. A configuração do DAQ normalmente é dinâmica, e pode ser mudada em tempo real, de forma a atender requisitos de balanceamento de carga e tolerância à falhas².

O DAQ é responsável por transferir dados provenientes de milhares de canais de leitura dos detetores para um único nó de execução. Ao longo deste processo, o evento precisa ser construído, o que significa que toda a informação sobre este evento precisa ser colocada no formato especificado pelo experimento. Após a construção do evento, algoritmos em *software* são executados para extrair informações físicas relevantes que culminem na rejeição ou aprovação do evento em questão. Se o evento for aprovado, é responsabilidade do DAQ enviá-lo para um sistema de armazenamento em massa.

Os experimentos $D\bar{O}$ e CDF utilizam um DAQ baseado em redes de alta velocidade para realizar a leitura da informação de seus detetores, após a execução de um segundo nível de filtragem híbrido (*hardware-software*). Os dados colhidos são propagados para um conjunto de nós de processamento rodando Linux para a decisão do terceiro nível.

O CMS e o ATLAS utilizam uma abordagem diferente para a execução da filtragem de alto nível. O ATLAS, antes da execução do terceiro nível de filtragem, implementa um segundo nível de filtragem que analisa apenas pequenas partes dos detetores, provendo cortes adicionais de eventos irrelevantes (maiores detalhes serão vistos no Capítulo 5). O CMS, por outro lado, desenvolveu um sistema de tráfego de dados capaz de propagar eventos completos aprovados pelo primeiro nível, e obtidos à uma taxa de 100 kHz, diretamente para seu sistema de filtragem de alto nível, composto por uma grande rede de processadores que produzirão a decisão final do sistema de filtragem do CMS.

²Tipicamente, sistemas de filtragem de alto nível são compostos por centenas de dispositivos, tornando vital a existência de mecanismos de controle de falhas.

Algoritmos de Filtragem Baseados em Calorimetria

Em [41], apresenta-se a abordagem utilizada para a identificação de elétrons no sistema de filtragem de alto nível do CMS. Para a filtragem baseada em calorimetria, um algoritmo analisa as células do calorímetro eletromagnético, procurando por possíveis regiões de interesse³. Quando uma região é encontrada, uma estimativa bastante precisa da energia da partícula é feita, empregando-se a granularidade completa do calorímetro, e somando-se a energia contida em uma região de 5×5 células em $\eta \times \phi$. Uma vez que a energia é calculada, o evento é aprovado caso o valor de energia obtido seja maior que um corte estabelecido [42].

No ATLAS, a identificação de elétrons baseada em calorimetria é feita, entre outros algoritmos, pelo T2Calo [43]. Este algoritmo calcula a razão entre a energia amostrada na seção hadrônica e eletromagnética do ATLAS, bem como a energia transversa do evento, e informações simples sobre o perfil lateral do chuveiro produzido no calorímetro eletromagnético. Diferentemente do primeiro nível de filtragem, o T2Calo emprega a granularidade total dos calorímetros do ATLAS. A decisão sobre a aceitação do evento é tomada através da aplicação de cortes lineares nas grandezas calculadas. O T2Calo será apresentado com mais detalhes na Seção 5.4.2.

Em [44], um sistema de discriminação elétron / jato baseado em redes neurais foi desenvolvido para o segundo nível de filtragem do ATLAS. Este algoritmo resume a informação depositada em cada camada do sistema de calorimetria do ATLAS através da produção de um conjunto de anéis topológicos, concêntricos à célula quente de cada camada. As células pertencentes a um dado anel são somadas, resultando em uma única variável para cada anel, produzindo, ao final, um total de 100 anéis. Antes de serem aplicados à rede neural classificadora, os anéis passam por uma normalização em energia, que visa reduzir, camada a camada, a influência da energia do evento no processo de classificação, bem como amplificar a informação contida nos anéis mais externos à célula quente, visto que é onde se encontra a informação relevante para a classificação.

A rede neural classificadora alimentada com as 100 somas em anéis contém 12 neurônios na camada escondida, e um único neurônio na camada de saída, ambos

³Uma região de interesse é encontrada quando uma dada célula ultrapassa um dado patamar de energia.

com função de ativação tangente hiperbólica. Para o conjunto utilizado naquele trabalho, uma eficiência de detecção de 97,5% foi obtida, para um falso alarme de 3,2%.

Em [45], foi desenvolvido um algoritmo de separação elétron / jato para operar, também, no segundo nível de filtragem do ATLAS. Tal como em [44], as células da região de interesse são organizadas, para cada camada, em anéis concêntricos à célula quente da camada. Para reduzir a influência da energia do evento, e realçar o perfil lateral do chuveiro produzido, os anéis são normalizados pela energia total da camada a que pertencem, porém, o fator de normalização é reduzido gradativamente para os anéis mais externos.

Para isolar-se a informação útil para a classificação, os anéis produzidos são projetados em seus componentes principais (PCA) [46] mais energéticos. O trabalho aborda diversas maneiras para a extração dos componentes, podendo esta ser realizada analisando-se toda a informação disponível em uma única extração, bem como extraindo-se os componentes de maneira segmentada (camada a camada). Com a análise de componentes principais, foi possível reduzir em 97% a dimensão da entrada para o caso segmentado, e em 90% para o caso não segmentado, ao passo que se preservou 95% da variância original dos dados, em ambas as abordagens.

Para a classificação, uma rede neural contendo 17 neurônios na camada escondida e um único neurônio na camada de saída é utilizada. Em ambas as camadas, a tangente hiperbólica foi adotada como função de ativação. Para o mesmo conjunto de dados empregados em [44], esta estratégia atingiu 97% de eficiência de detecção de elétrons, para um falso alarme inferior a 3%.

4.2 Sistemas de Filtragem *Offline*

Conforme explicado na Seção 4.1, para sistemas de filtragem *online*, uma vez que um evento é rejeitado, não é possível recuperar o mesmo. Desta forma, para evitar a perda de um canal físico relevante, a eficiência de detecção é aumentada, com o custo de aumentar, também, o falso alarme. Conseqüentemente, ao final de um sistema de filtragem *online*, ainda se encontram eventos, provenientes de ruído de fundo, misturados com os canais de interesse. Adicionalmente, os dados armazenados serão

destinados a inúmeros estudos distintos (matéria escura, bóson de Higgs, supersimetria, etc.), onde cada estudo necessitará observar um determinado subgrupo de eventos armazenados após a filtragem *online*.

Para atender a estes casos de uso bastante diversificados, normalmente sistemas de filtragem *offline* são empregados. Neste modelo de filtragem, uma vez que o tempo de processamento não é um fator crítico, algoritmos mais complexos e eficientes podem ser empregados para analisar cada evento, de acordo com requisitos específicos ao estudo sendo conduzido.

Normalmente, técnicas baseadas na estimação da função densidade de probabilidade (PDF) do sinal de interesse são exploradas. Métodos baesianos de análise são frequentemente utilizados para testar a hipótese de ocorrência de um determinado canal físico de interesse. Hipóteses também podem ser testadas ao comparar-se se a PDF do canal físico desejado está similar à distribuição de probabilidade descrita pela teoria para este canal. Neste caso, testes de χ^2 [47] também são empregados.

Redes neurais artificiais podem ser encontradas com frequência em sistemas de filtragem *offline*, provendo eficiência de filtragem superior a métodos lineares de filtragem [48]. Por exemplo, em [49], uma rede neural é empregada para realizar a identificação de pares $W^+W^- \rightarrow q\bar{q}q\bar{q}$. Estes pares encontram-se imersos em ruído $Z/\gamma \rightarrow q\bar{q}(g)$, $ZZ \rightarrow q\bar{q}q\bar{q}$ e $ZZ \rightarrow q\bar{q}\tau^+\tau^-$. Nota-se que sinal e ruído produzem pares $q\bar{q}$, o que dificulta bastante a tarefa de separação. 13 variáveis de entrada são fornecidas à rede neural. Estas variáveis foram selecionadas de acordo com diferentes critérios, tais como a energia transversa do evento, o número de jatos encontrados, rapidez e o teste de χ^2 realizado sobre a distribuição de energia de jatos. A rede neural emprega 7 neurônios na camada escondida, e um neurônio na camada de saída. Como resultado, esta abordagem provê uma eficiência de detecção de $\sim 80\%$ para um falso alarme de $\sim 30\%$.

Em [50], várias técnicas multivariáveis, tais como redes neurais e estimadores de máxima-semelhança, são apresentadas para a identificação *offline* de τ -léptons decaindo hadronicamente. As variáveis empregadas para identificar esta assinatura são baseadas no perfil de deposição de energia no calorímetro eletromagnético e o perfil do traço associado. No caso específico das redes neurais, para uma mesma probabilidade de detecção, uma melhora de aproximadamente uma ordem de grandeza

foi obtida na probabilidade de falso alarme, quando comparada com a aplicação de limiares de corte em cada variável individualmente.

Capítulo 5

Sistema de Filtragem do ATLAS

Como visto no Capítulo 2, o detetor ATLAS é finamente segmentado. A cada colisão, aproximadamente 1,5 MBytes de informação serão produzidos. Ao multiplicar-se este valor pela taxa de colisões, obtém-se um volume de informação da ordem de 60 TBytes por segundo. Adicionalmente, canais físicos de interesse ocorrem com um período que varia de algumas horas a até dias de operação. Conseqüentemente, um sistema de filtragem *online* torna-se indispensável para o experimento. O sistema de filtragem deverá identificar os padrões de decaimento do Higgs, e demais eventos de interesse, para poder localizá-los na massa de eventos com física ordinária, produzida pelas interações mal-sucedidas (nesse contexto, interações que produzem canais físicos já conhecidos e que, portanto, significam ruído de fundo para o experimento).

O sistema de filtragem (*trigger*) do ATLAS e o sistema de aquisição de dados são baseados em três níveis sequenciais de seleção *online* de eventos. Partindo de uma taxa de eventos de 40 MHz, a taxa de eventos armazenados precisa ser reduzida, ao final do processo de seleção, para aproximadamente 100 Hz, para fins de uma posterior análise *offline*. Enquanto se requer uma alta taxa geral de rejeição, a eficiência na identificação dos eventos de interesse precisa ser elevada [51].

Observa-se na Figura 5.1 o diagrama em blocos do sistema de *trigger* do ATLAS. Como se percebe, o mesmo está dividido em três níveis principais de validação. A informação gerada por parte dos detetores é passada para o primeiro nível, que realiza a análise inicial, com uma granularidade menos fina. Os eventos aprovados pelo primeiro nível são armazenados em *buffers* de leitura, para que possam ser acessados pelos níveis seguintes. O segundo nível opera somente sobre as regiões

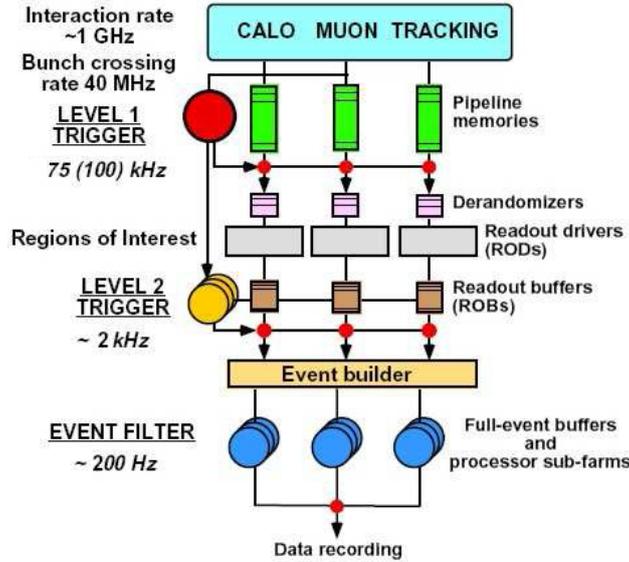


Figura 5.1: Diagrama em blocos do sistema de filtragem.

de interesse marcadas pelo primeiro nível, validando a decisão do mesmo, desta vez utilizando a plena granularidade. Em seguida, os eventos aprovados no segundo nível são enviados ao filtro de eventos (terceiro nível), onde a informação completa de cada evento é utilizada. Por fim, os eventos que são aprovados pelo filtro de eventos são enviados para armazenamento em disco para posterior análise *offline*. Maiores detalhes sobre os três níveis de filtragem serão apresentados a seguir.

5.1 Primeiro Nível de *Trigger*

O primeiro nível de *trigger* (L1) realiza a seleção inicial, baseando-se na informação obtida com granularidade menos fina de um subconjunto de detetores (calorímetros e detetores rápidos de múons [52]). A granularidade neste nível não é plena, uma vez que o tempo para a tomada de decisão neste nível é tão curto que torna-se necessária a redução da quantidade de informação a ser processada, de modo a se aumentar a velocidade de processamento. Assim, agrupam-se as células dos calorímetros (eletromagnético e hadrônico) em conjuntos contendo 6 células. As células de cada conjunto são analogicamente somadas, produzindo um único sinal [53, 54]. Consequentemente, este primeiro nível só descarta eventos com características bastante distintas dos canais de interesse. Múons de momento transverso (p_T) elevado são identificados usando apenas as chamadas câmaras de *trigger*, câmaras de placas

Tabela 5.1: Exemplo de frequência de observação de eventos no primeiro nível, com luminosidade máxima ($L = 10^{34} \text{ cm}^{-2}\text{s}^{-1}$)

Assinatura	Frequência (kHz)
Múon único com $p_T > 20 \text{ GeV}$	4
Par de múons com $p_T > 6 \text{ GeV}$	1
Evento eletromagnético isolado com $E_T > 30 \text{ GeV}$	22
Par de eventos eletromagnéticos isolados com $E_T > 20 \text{ GeV}$	5
Jato único com $E_T > 290 \text{ GeV}$	0.2
Três jatos com $E_T > 130 \text{ GeV}$	0.2
Quatro jatos com $E_T > 90 \text{ GeV}$	0.2
Jato único com $E_T > 100 \text{ GeV}$ e $E_{T\text{miss}} > 100 \text{ GeV}$	0.5
Tau único com $E_T > 60 \text{ GeV}$ e $E_{T\text{miss}} > 60 \text{ GeV}$	1
Múon único com $p_T > 10 \text{ GeV}$ e evento eletromagnético isolado com $E_T > 15 \text{ GeV}$	0.4
Outros eventos	5
Total	~ 40

resistivas (RPC) no barril, e câmaras de abertura fina nas beiradas [55].

Conforme discutido em [56], a maioria das análises físicas que foram consideradas no ATLAS podem ser feitas, no primeiro nível, usando critérios de seleção relativamente simples. Entretanto, a implementação do primeiro nível é flexível e pode ser programada para selecionar eventos usando critérios mais elaborados.

Pode se observar na Tabela 5.1 a taxa de frequência de ocorrência esperada para as várias assinaturas relevantes para o ATLAS. Por exemplo, par de eventos eletromagnéticos isolados com $E_T > 20 \text{ GeV}$ são importantes para o estudo do canal $H \rightarrow ZZ \rightarrow 4e$ (bóson de Higgs decaindo em $2Z$, cada um decaindo em 2 elétrons). A taxa máxima de saída do primeiro nível de filtragem está limitada em 75 kHz (podendo ser expandida para 100 kHz). Conforme pode-se concluir da Tabela 5.1, as taxas estimadas dos eventos de interesse correspondem, no total, à metade do limite máximo de aceitabilidade do primeiro nível. Entretanto, devido às incertezas intrinsecamente presentes nestes cálculos, considera-se que esta margem de segurança não está superestimada [51].

Um requisito básico para o primeiro nível é que este deve identificar unicamente colisões de interesse. Dado o pequeno intervalo de tempo (25 ns) entre choques de dois pacotes de prótons, esta é uma consideração não trivial. No caso dos calorímetros, por exemplo, um desafio considerável a ser vencido é o fato do pulso gerado por estes dispositivos poder se estender por várias colisões (efeito de *pile-*

up [15]), o que degrada o sistema de *trigger*.

É importante que se mantenha o tempo de latência no valor mais baixo possível. Durante este tempo, a informação de todos os canais do detetor precisa ser retida em memórias do tipo *pipeline* [54]. Estas memórias estão geralmente contidas em circuitos integrados, posicionados próximos ou junto ao detetor, frequentemente em regiões inacessíveis e imersas em ambientes de forte radiação. A latência do primeiro nível, medida do instante de uma colisão próton-próton até a decisão do primeiro nível estar disponível para o nível seguinte, deve ser menor que $2,5 \mu\text{s}$ [51]. De forma a atingir esta exigência, o primeiro nível de *trigger* está sendo implementado em *hardware* de baixa programabilidade, na tecnologia de FPGA (*Field Programmable Gate Array*). O tempo de latência desejado para este nível de *trigger* foi estipulado em $2 \mu\text{s}$, deixando-se 500 ns de margem de segurança.

Um evento selecionado pelo L1 é etiquetado por este com a identificação do potencial canal físico a que pertence (identificado a partir da informação limitada do L1), e em seguida, é lido dos *drivers* de saída dos detetores (*Read Out Drivers* - ROD) e propagado para os *Readout Buffers* (ROB) através dos cabos de leitura (*Read Out Links* - ROL), ficando, assim, disponível como fragmentos de informação (vide Seção 5.3) para o sistema de filtragem de alto nível.¹ Entretanto, de forma a reduzir o volume de tráfego de dados para o segundo nível, e, conseqüentemente, aumentar a banda passante entre estes dois níveis, o primeiro nível já marca as regiões de interesse (*Region of Interest* - RoI), de tal maneira que o segundo nível observará somente estas regiões de interesse, e não toda a área do detetor.

5.2 O Sistema de Filtragem de Alto Nível

O sistema de filtragem de alto nível do ATLAS (*High Level Trigger* - HLT) é composto pelo segundo nível (*L2*) e pelo filtro de eventos (*Event Filter* - EF), ambos implementados em *software* com linguagem de programação de alto nível. A Figura 5.2 apresenta os detalhes desta parte do sistema de filtragem. Após a filtragem do L1, os eventos aprovados ficam disponíveis na forma de fragmentos nos sistemas de leitura (*Read-Out Systems* - ROS). Além disso, a informação a respeito das RoIs

¹A parte de alto nível do sistema de *trigger* corresponde ao segundo e terceiro níveis, visto que são desenvolvidos em *software* e executados em computadores de uso geral.

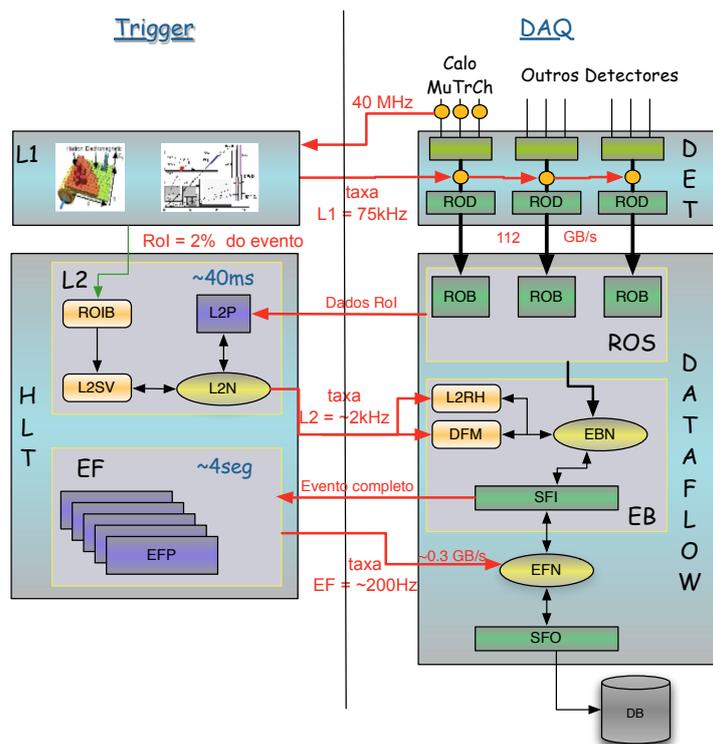


Figura 5.2: Diagrama em blocos do sistema de filtragem de alto nível.

etiquetadas pelo L1 é enviada para o construtor de RoI (*RoI Builder* - RoIB). Este agrupa os fragmentos de informação gerados pelos diferentes detetores do ATLAS e transmite o registro gerado por este agrupamento para um supervisor do segundo nível (*L2 Supervisor* - L2SV), que ficará responsável por atribuir a RoI recebida a uma unidade de processamento do segundo nível (*L2 Processing Unit* - L2PU). A L2PU então valida a etiqueta do L1, usando a plena granularidade dos detetores, e retorna o resultado para o L2SV. Este envia o resultado para o gerenciador de fluxo de dados (*Dataflow Manager* - DFM), para que o evento seja apagado em caso de rejeição, ou propagado para o filtro de eventos, caso seja aprovado. O DFM seleciona um dos processadores SFI (*Sub-Farm Input*) para que o mesmo solicite aos ROS toda a informação disponível do evento em questão. Uma vez a informação disponível, o SFI seleciona um dos processadores do filtro de eventos (*EF Processor* - EFP), para que o mesmo realize análises detalhadas, usando toda a informação disponível para cada evento, e gerando, assim, a decisão final do sistema de filtragem. Os eventos finalmente aprovados são enviados aos processadores SFO (*Sub-Farm Output*) para que possam ser armazenados em mídia permanente, permitindo posterior análise

Módulo	Nº de Processadores
ROS	150
RoIB	1
L2SV	12
L2PU	500
DFM	12
SFI	100
EFP	1.900
SFO	5
Controle	20
Monitoração	32

Tabela 5.2: Quantidade de processadores necessários para cada módulo do sistema de filtragem de alto nível do ATLAS.

offline. A Tabela 5.2 apresenta o número de processadores necessários para cada módulo do sistema de filtragem de alto nível do ATLAS, considerando máquinas com 4 núcleos de processamento com *clock* de 3,2 GHz cada [57]. A quantidade de processadores necessários para cada módulo deixa claro a complexidade da estrutura computacional necessária para sustentar a elevada taxa de eventos no sistema de filtragem de alto nível.

Todo o segundo nível de filtragem foi desenvolvido utilizando, o máximo possível, tecnologias padronizadas (comerciais) [58], visando fácil reposição de material e implementação simplificada. Todos os processadores são de uso geral (tipo PC) e praticamente todas as comunicações entre estes dispositivos são feitas através de *switchs* Gigabit Ethernet, devido à velocidade, confiabilidade e padronização do protocolo. Todas as aplicações também estão desenvolvidas utilizando técnicas de orientação a objetos e implementadas em C++ [59].

O sistema de filtragem de alto nível está dividido em duas partes: a aquisição e controle de dados e o processamento dos eventos produzidos pelo ATLAS. Estas duas partes, juntas, são referidas como TDAQ (*Trigger and Data Aquisition*), e serão descritas a seguir.

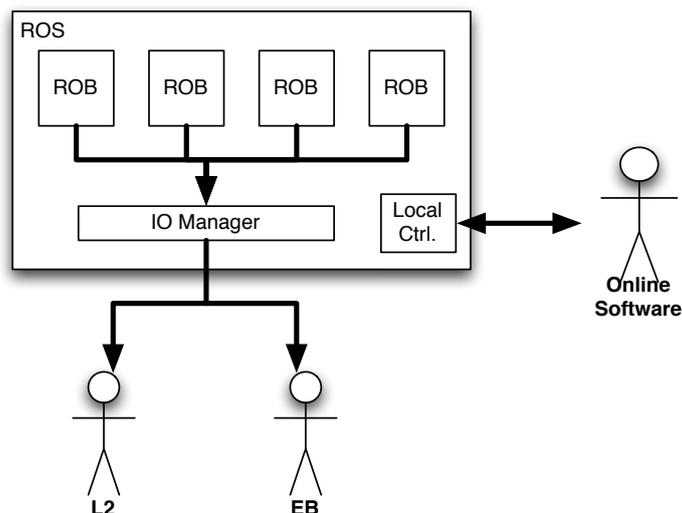


Figura 5.3: Diagrama dos submódulos do ROS.

5.2.1 Aquisição e Controle de Dados (*Data Acquisition and Control - DAQ*)

O DAQ é responsável pela propagação dos eventos pelo sistema de filtragem de alto nível do ATLAS. É responsabilidade de seus módulos garantir a integridade e correto fluxo da informação por todo o sistema. Além disso, o DAQ precisa assegurar que a informação chegará em tempo hábil, para atender os restritos requisitos de tempo. Por fim, o DAQ também é responsável por prover mecanismos de monitoração dos seus módulos, de forma a assegurar que os mesmos estejam funcionando corretamente. A seguir, serão apresentados os módulos que compõem o DAQ.

Sistemas de Leitura (*Read-Out Systems - ROS*)

Os ROS são computadores de uso geral, tipo PC, que servem de interface entre o sistema de filtragem de alto nível e os eventos aprovados pelo L1. O ROS possui 3 componentes principais (veja a Figura 5.3): o *Buffer* de Leitura (*Read-Out Buffer - ROB*), o *IOManager* e o *Controlador Local*.

O ROB provê armazenamento temporário dos fragmentos de informação produzidos por um dado ROD, para que sejam acessados pelo L2 e pelo Construtor de Eventos. Conseqüentemente, o ROB receberá fragmentos na taxa de saída do L1, ou seja, 75 kHz. Todos os fragmentos de informação vindo de um ROD ficam

armazenados pelo tempo de latência do L2, e aproximadamente 3% destes, durante o tempo da construção do evento pelo Construtor de Eventos (EB), considerando-se 2 kHz de taxa de aprovação para o L2. Cada ROS possui 12 ROB e cada ROB fica conectado a um único ROD, através de um ROL. Para o tráfego dos fragmentos de informação com o sistema de filtragem, é utilizada uma rede gigabit ethernet dedicada para os dados do L2. Utiliza-se ainda uma outra rede deste tipo para os dados do Construtor de Eventos, de forma a diminuir o tempo de espera por fragmentos de informação.

O *IOManager* processa os requisitos de dados oriundos das L2PU e dos SFI. Dependendo do que é especificado na requisição do dado, o *IOManager* coleta um ou mais fragmentos de ROB de um ou mais ROB, gera um fragmento de ROS (vide Seção 5.3) contendo os fragmentos de ROB selecionados, e envia este fragmento para o componente solicitante. O *IOManager* também recebe do DFM requisições para liberar o espaço utilizado por fragmentos de ROB que já foram utilizados e devem ser apagados. Para otimizar a performance global do ROS, o *IOManager* permite transmissões simultâneas de dados, graças à sua arquitetura *multi-thread* adotada pelo *IOManager*.

O Controlador Local provê a interface entre o ROS e o software *online*. Ele configura, controla e monitora todos os componentes dentro do ROS. A monitoração compreende tanto a monitoração operacional (tamanho de filas, páginas de memória utilizada, etc.), e a provisão de amostras dos fragmentos de informação fluindo pelo ROS, com o objetivo de monitorar os detetores. O Controlador Local comunica-se com o software *online* através da rede de controle, de forma a não impactar na velocidade de transmissão de fragmentos de informação do ROS.

Geradores de Regiões de Interesse (*RoI Builders - RoIB*)

Para cada evento aceito, o primeiro nível envia informações como a posição da RoI e valores de limiar alcançados. O RoIB combina estes fragmentos em um único registro que é passado a um L2SV. No esquema básico, cada L2SV verá apenas um subconjunto de L2P, de tal forma que a escolha do L2SV afeta o balanço de carga entre os L2P. O critério de seleção de L2SV utilizado pelo RoIB é o *round-robin* [60].

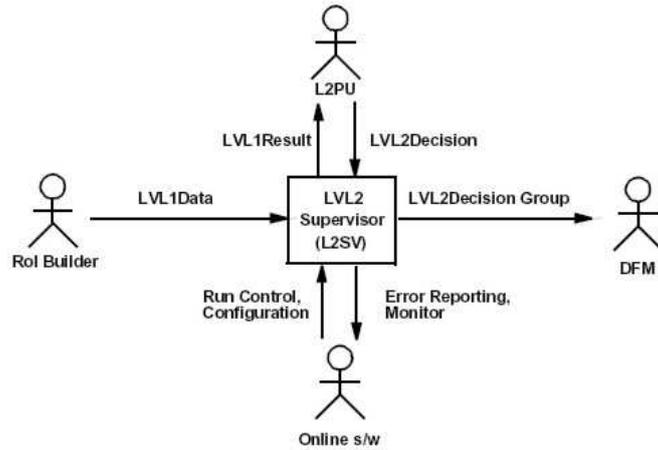


Figura 5.4: Contexto do supervisor do segundo nível.

Supervisor do Segundo Nível (*L2 Supervisor - L2SV*)

Os supervisores do segundo nível (L2SV) formam um pequeno grupo de 12 processadores que supervisionam o fluxo de eventos no segundo nível e atuam como mediadores entre os sistemas do primeiro e do segundo nível. De forma a simplificar o gerenciamento dos processadores, os processadores utilizados para este fim serão de tipo similar aos que serão utilizados para a seleção de eventos. Entretanto, cada processador supervisor precisa de uma interface para receber dados do RoIB [61].

O contexto do supervisor do L2SV é indicado na Figura 5.4. O L2SV recebe do RoIB a informação do primeiro nível em um único registro. O supervisor seleciona, então, um L2P para o evento e passa para uma das unidades de processamento (L2PU)² o dado do primeiro nível. Uma vez que o algoritmo foi executado e uma decisão quanto ao evento foi tomada, a mensagem de decisão é passada para o L2SV. O Resultado é propagado, então, para o controlador de fluxo de dados (*Data Flow Manager - DFM*) e para o L2RH.

Ao selecionar um L2P, o supervisor o faz através de uma função de balanceamento de carga, examinando o número de eventos na fila e associando cada evento ao processador menos carregado no momento [61].

²Um L2P pode ter várias L2PUs sendo executadas simultaneamente, visando maximizar a eficiência de uso da CPU.

Manipulador de Resultados do Segundo Nível (*L2 Result Handler - L2RH*)

Para todos os eventos aceitos pelo segundo nível, os detalhes do processamento deste nível (e o resultado completo do primeiro nível, recebido pelo supervisor) são fornecidos pela L2PU para que sejam incluídos ao evento. Entretanto, os ROS só armazenam dados provenientes do L1. Para resolver este problema, o L2RH foi desenvolvido. Este componente opera de maneira bastante similar ao ROS, só que recebe a informação gerada pelo L2. A informação do L2 é enviada via rede como um fragmento de ROB para o L2RH, onde é armazenada, enquanto aguarda sua requisição pelo construtor de eventos, que enxerga o L2RH como um ROS. Quando o evento é construído, o L2RH é inserido com todos os outros ROSs, de forma a incluir o resultado do segundo nível na construção do evento, que será enviado ao filtro de eventos. Uma única unidade como essa é suficiente para lidar com o volume de dados ao final do segundo nível, onde se espera um fluxo de uns poucos kBytes por segundo, considerando uma taxa de aceitação de 3 kHz.

Gerenciador de Fluxo de Dados (*Dataflow Manager - DFM*)

Este componente se encarrega de receber os resultados das decisões realizadas pelo L2. Eventos rejeitados são salvos em uma fila, de forma que, quando esta fila enche, o DFM dispara uma mensagem para todos os ROS solicitando que estes removam de seus ROB os fragmentos de informação pertencentes aos eventos rejeitados. Para os eventos aprovados, o DFM opera de maneira análoga ao L2SV. Ele seleciona um SFI menos carregado e envia a este as informações de um dado evento aprovado, para que este seja construído pelo SFI. Ao final da construção do evento, o DFM solicita aos ROS que apaguem os fragmentos de informações referentes a este evento, visto que durante a construção, estes fragmentos são copiados para o SFI, de forma a liberar espaço nos ROB.

Fazendas de Entrada (*Subfarm Input - SFI*)

O SFI é o dispositivo encarregado de requisitar e receber todos os fragmentos de dados de um determinado evento, para a que o mesmo seja montado e propagado ao filtro de eventos. Após a montagem do evento, o SFI informa ao DFM que o evento

já foi corretamente montado, de forma que o DFM possa solicitar aos ROS que apaguem as informações referentes ao evento montado. Para aumentar a eficiência de utilização de um SFI, várias *threads* operam concorrentemente, permitindo a construção de vários eventos em paralelo dentro de um mesmo SFI. O SFI também é responsável por enviar a um processador do filtro de eventos o evento totalmente construído. Somente após o processador do filtro de eventos acusar o correto recebimento do evento montado, o mesmo é apagado da memória do SFI [62].

Fazendas de Saída (*Subfarm Output* - SFO)

Após a validação final de cada evento pelas PT, os eventos aprovados devem ser finalmente armazenados em mídia permanente para posterior análise *offline*. Quando um EFD aprova um evento, ele o envia para o SFO, para que o mesmo o armazene em arquivos em disco. Estes arquivos são posteriormente acessados por um sistema de armazenamento em massa para armazenamento definitivo [61].

5.2.2 Unidades de Processamento

As unidades de processamento do sistema de filtragem de alto nível do ATLAS são responsáveis pela filtragem propriamente dita. São estas unidades que, ao analisar cada evento, decidirão se o mesmo deve ou não ser descartado.

Processadores do Segundo Nível (*L2 Processors* - L2P)

O algoritmo de seleção do segundo nível é executado em uma rede de processadores do tipo PC com múltiplos núcleos de processamento. O tempo total de decisão médio, para cada evento do segundo nível, é de aproximadamente 40 ms. Entretanto, haverá uma grande variação entre os tempos gastos com cada evento, uma vez que certos eventos podem ser descartados logo no início do processo de seleção do segundo nível, enquanto que outros terão que ser propagados até o fim, para que uma decisão possa ser tomada (veja a Seção 5.2.4). Cada evento é manipulado por um único processador, que requisita aos ROS os dados de cada RoI somente quando solicitado pelo algoritmo. Para manter uma alta eficiência de utilização de cada processador, múltiplas *threads* são utilizadas, de forma que vários eventos são processados em paralelo dentro de um mesmo processador.

O processamento é executado em um único aplicativo rodando em cada processador. Este aplicativo contém três componentes principais: a unidade de processamento do segundo nível (*L2 Processing Unit* - L2PU), a interface de comunicação PESA (*PESA Steering Controller* - PSC) e o *software* de seleção de eventos (*Events Selection Software* - ESS). A L2PU lida com o fluxo de dados com outras partes do sistema de *trigger*, incluindo envio de mensagens, configuração, controle e supervisão. A interface PSC é executada dentro da L2PU e provê o ambiente e serviços necessários para o ESS. Como a L2PU controla a comunicação com o L2SV e os ROS, algumas interfaces precisam ser providas para as várias mensagens entre a L2PU e o ESS. A PSC provê a interface para o resultado do primeiro nível e retorna o resultado do segundo nível. Maiores detalhes sobre o ESS estão apresentados na Seção 5.2.4.

O desenvolvimento e implementação das L2PUs são baseados em um ambiente [61] do qual são utilizados os seguintes serviços: controle, inicialização e configuração de aplicativos, relatório de erros, monitoração e envio de mensagens de aplicativos e instrumentação (este último para avaliação de performance).

As L2PU se comunicam com os supervisores do segundo nível, recebendo destes a informação da RoI (gerada pelo primeiro nível) e retornando a decisão do segundo nível. Os dados da RoI (provenientes de vários ROB) são requisitados dos ROS, de acordo com a necessidade dos algoritmos de seleção.

Os algoritmos de seleção propriamente ditos são executados dentro de uma das *threads* de execução (*Worker Threads*), cada uma processando um evento. Esta abordagem *multi-thread* foi adotada para evitar a suspensão do trabalho da CPU enquanto a mesma aguarda pelo dado solicitado ao ROS. Este recurso também permite o uso eficiente de processadores contendo múltiplas CPUs, mas requer que o algoritmo de seleção de eventos seja seguro, no que diz respeito a esta implementação. Alguns serviços assíncronos (monitoração de aplicativos, entrada de dados) também são executados em *threads* separadas.

Pode-se observar, na Figura 5.5, o que acontece para cada evento no L2. O supervisor do segundo nível seleciona uma L2PU e envia o resultado do primeiro nível para o evento a ser processado. Esta L2PU armazena o resultado recebido em uma fila compartilhada. Quando uma *thread* fica disponível, a mesma retira da

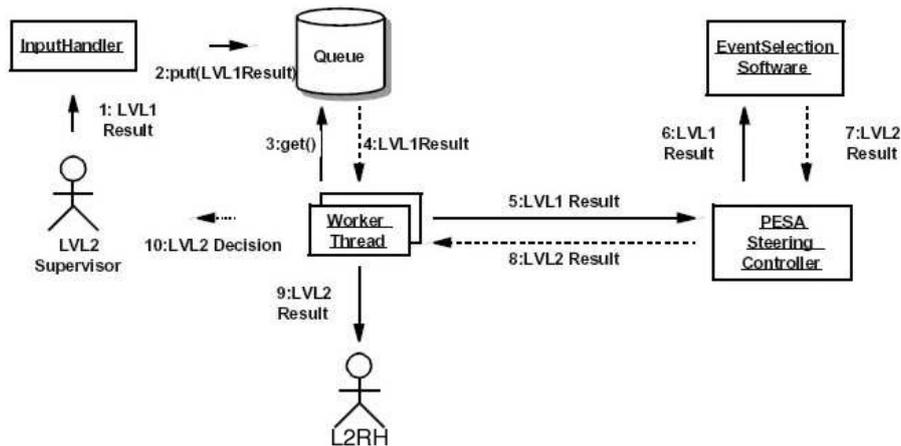


Figura 5.5: Fluxo de processamento para cada evento recebido do primeiro nível e que leva a uma decisão do segundo nível.

fila um evento, inicia o processamento do mesmo e produz, ao final, o resultado do segundo nível. Finalmente, a decisão do segundo nível é gerada a partir do resultado produzido pela *thread* e retornado ao supervisor do segundo nível. Se o resultado for positivo, o resultado é enviado, também, para o L2RH.

Processador do Filtro de Eventos (*Event Filter Processors - EFP*)

O EFP é o componente que solicitará ao SFI ao qual está conectado, um evento construído, para realizar a validação final sobre o mesmo. Cada EFP executa um programa de controle de fluxo de dados (*Event Filter Dataflow - EFD*) que receberá dos SFI os eventos construídos. Adicionalmente, cada EFP possui várias Unidades de Processamento (*Processing Tasks - PT*). As PT são encarregadas de processar os eventos recebidos pelo EFD. Enquanto a L2PU observa apenas parte do detetor (RoI), a PT analisará toda a informação disponível para cada evento. Quando uma dada PT completa o processamento de um evento, ela requisita um novo. Os dados gerados pela PT durante o processamento são anexados ao evento completo, caso tenha sido aceito pela PT. Os eventos aceitos são classificados e movidos para o respectivo SFO, para serem gravados em arquivos em disco.

Os EFP estão organizados em conjuntos, onde cada conjunto está associado a um ou mais SFI ou SFO. SFI, SFO e os EFP estão conectados através de um *switch* Ethernet de alta velocidade (Gigabit Ethernet).

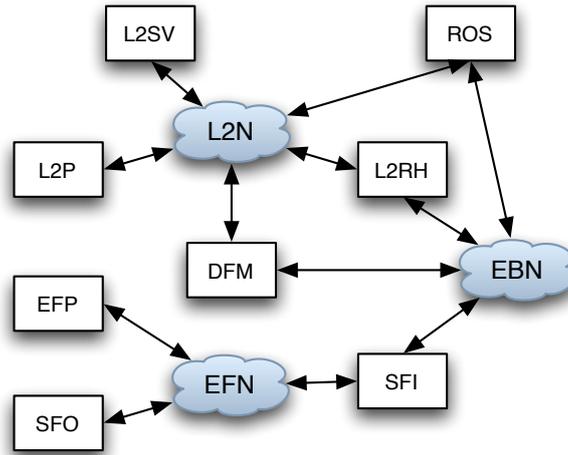


Figura 5.6: Diagrama de conexão das redes de dados do HLT.

5.2.3 Comunicação entre os Módulos do Sistema de Filtragem

Para a transmissão de dados entre os módulos do sistema de filtragem de alto nível do ATLAS, utiliza-se *switchs* Gigabit *ethernet*. Para lidar com o enorme fluxo de informações, existem redes específicas para cada parte do sistema de filtragem de alto nível. A rede de controle (*Control Network* - CTRLN) conecta todos os dispositivos. Informações de configuração, monitoração, notificações de erros são transmitidas por cada módulo utilizando esta rede. A rede de tráfego do segundo nível (*L2 Network* - L2N) é responsável pelo tráfego de dados dos componentes pertencentes a este nível. Os L2SV enviam as informações sobre a RoI a ser validada para o L2P utilizando esta rede, e as L2PU requisitam aos ROS os fragmentos de informação necessários também utilizando esta rede. A L2N também conecta o L2SV com o DFM e o L2RH. A rede do construtor de eventos (*Event Builder Network* - EBN) será utilizada para trafegar os dados a serem construídos entre os ROS, L2RH, DFM e SFI. Por fim, a rede do filtro de eventos (*Event Filter Network* - EFN) conecta os EFP com os SFI e SFO. É apresentado na Figura 5.6 o diagrama com a conexão das redes de tráfego de dados do sistema de filtragem de alto nível, para melhor visualização.

Como apresentado nesta seção, o volume de informação trafegando entre o L1 e o HLT é muito elevado. Além disso, o L1 opera próximo ao ATLAS, enquanto o HLT opera na superfície, separado do L1 por aproximadamente 200 metros. Consequen-

temente, a interface entre estas duas partes possuem alguns requisitos especiais, a saber:

- Palavra de 32 bits à 40,08 MHz (~ 160 Mbyte/s).
- Resistência à radiação.
- Latência muito pequena.
- Comprimento máximo de 300 metros.

Estes requisitos tornam inviável a utilização de redes Gigabit *ethernet*. Desta forma, os ROS e o RoIB estão conectados aos detetores do ATLAS por cabos de fibra óptica, usando protocolo de comunicação S-LINK [63]. O protocolo S-LINK é uma protocolo de comunicação ponto-a-ponto desenvolvido especialmente para atender os rígidos requisitos de transmissão entre o L1 e o HLT. Ao contrário de outros padrões, que definem a camada física de transmissão, o S-LINK define uma simples interface FIFO síncrona na qual os sinais de transmissão ficam independentes do canal físico. O mapeamento entre os sinais da S-LINK e do protocolo usado na camada física fica a critério do desenvolvedor do canal de transmissão, de forma que este pode realizar este mapeamento da forma mais adequada à tecnologia adotada no canal de transmissão.

5.2.4 Athena

O requisito básico exigido pelos físicos para realizarem suas tarefas é um conjunto de programas para realizar simulações de eventos, reconstruções, visualizações, etc. Além de um conjunto de ferramentas que permitam a escrita de programas de análises. Adicionalmente, os físicos desejam algo fácil de usar e extremamente flexível. Por fim, os físicos do ATLAS desejam desenvolver algoritmos de seleção de eventos para operarem *online* no sistema de filtragem do ATLAS.

Para suprir estes requisitos, o Athena foi desenvolvido. O Athena é um *framework* de controle que representa uma implementação concreta de uma arquitetura. A arquitetura por baixo do Athena é a arquitetura do Gaudi [64], originalmente desenvolvida para o LHCb. Esta arquitetura foi estendida através da colaboração com o ATLAS, e uma arquitetura base, desacoplada a um experimento específico, e

também chamada Gaudi foi desenvolvida. O Athena é, então, a união desta arquitetura base com melhorias específicas ao ATLAS [65].

O objetivo principal do Athena é isolar seus usuários de detalhes irrelevantes, como que tipo de biblioteca usar para transferência de dados, ou para gerar um gráfico. Para tal, sua arquitetura consiste na especificação de um número de componentes e suas interações entre si. Um componente é um bloco de código que possui uma funcionalidade e interface bem definida. Uma interface é uma coleção de métodos junto com uma descrição sobre o que cada método faz, ou seja, sua funcionalidade. Os principais benefícios desta abordagem são:

- **Flexibilidade:** esta abordagem provê simplicidade, dado que componentes podem ser conectados de diferentes maneiras para desempenhar diferentes tarefas.
- **Simplicidade:** softwares para acessar, por exemplo, uma base de dados, são normalmente complexos de se aprender. Entretanto, a maioria dos detalhes são de pouco interesse para alguém que deseja simplesmente ler dados e salvar seus resultados. Desta forma, um componente para acessar dados pode ser desenvolvido de forma a fornecer somente a funcionalidade desejada. Além disso, a interface para este componente continuaria a mesma, independentemente da tecnologia de armazenamento utilizada pela base de dados do exemplo em questão.
- **Robustez:** como dito acima, um determinado componente pode ocultar de seu usuário a tecnologia que utiliza. Além de oferecer simplicidade, a vantagem que isto representa é que a tecnologia pode ser alterada sem que o usuário precise sequer saber desta mudança.

Alguns dos principais serviços e interfaces do Athena são:

- **Pythia:** o Athena provê interface para o Pythia. Este módulo é responsável por simular a colisão de feixes de partículas.
- **Geant:** o Geant é um conjunto de ferramentas que permitem simular a interação de partículas com a matéria. Desta forma, torna-se possível simular o comportamento dos detetores do ATLAS quando excitados por partículas.

As simulações de Monte Carlo utilizadas para a análise e desenvolvimento de algoritmos de seleção são produzidas através da simulação de colisões geradas pelo Pythia, e a consequente descrição do comportamento dos detetores do ATLAS utilizando o Geant para descrever como estas partículas produzidas pelo Pythia interagem com o material que compões dos detetores do ATLAS.

- **Storegate:** O Storegate é um ambiente que permite a propagação de dados entre pacotes do Athena. Ele funciona como uma área de armazenamento, onde um dado algoritmo pode identificar e salvar informações geradas pelo mesmo no Storegate, de forma que os algoritmos subsequentes possam recuperá-lo, ao fornecer ao Storegate a chave de identificação do dado desejado.

Dada a flexibilidade do Athena, este está sendo utilizado para o desenvolvimento de algoritmos de seleção de eventos. Estes algoritmos podem acessar as simulações de Monte Carlo que reproduzem a colisão de partículas e a consequente interação destas com os detetores do ATLAS para realizar processos de extração de características e tomadas de decisão. Muitos destes algoritmos operam somente em modo *offline*. Entretanto, como dito acima, o Athena também será usado na filtragem *online* do ATLAS, de forma que uma família especial de algoritmos foi desenvolvida para atender a este objetivo.

Estratégia *Online* para a Seleção de Eventos

Como dito anteriormente, os eventos de interesse para o experimento ATLAS são bastante raros. Desta forma, lida-se com um volume muito maior de informação irrelevante, do que com eventos de interesse. Assim, a melhor estratégia de filtragem é rejeitar, o mais rápido possível, eventos considerados como ruído de fundo. A configuração e capacidades do sistema de filtragem de alto nível são dirigidas pela performance física (seleção de eventos e rejeição de ruído) e pela performance do sistema (velocidade de execução, requisitos de dados). O melhor compromisso entre estes fatores tem que ser encontrado de forma a maximizar a performance física. Para rejeitar eventos o mais rápido possível, uma abordagem de filtragem em etapas foi escolhida pelo ATLAS, tanto para o L2, como para o EF.

Para esta abordagem, um mecanismo de controle foi desenvolvido. Suas principais características são:

- Manter-se informado sobre quais algoritmos já foram executados para um dado evento, quais informações foram geradas por cada algoritmo e onde estas estão armazenadas. Adicionalmente, ele provê os mecanismos de persistência e propagação da informação, e provê mecanismos de acesso à informação gerada por cada algoritmo.
- Formar e manipular o resultado gerado para cada evento.
- Acessar os resultados do L1 e do L2, que dará origem aos subsequentes passos de reconstrução.

No contexto deste controle, algumas entidades estão presentes:

- **Elemento de *Trigger***: entidade que é ativada por um determinado algoritmo para sinalizar a validação de um corte. No L1, um elemento de *trigger* é uma RoI. Já no sistema de filtragem de alto nível, eles são gerados através de sequências de algoritmos de extração de características e testes de hipótese.
- **Assinatura**: combinação de elementos de *trigger* que podem levar a uma decisão positiva do sistema de filtragem. Os elementos de *trigger* podem ser combinados por lógica booleana AND, OR e NOT. Adicionalmente a multiplicidade de elementos de *trigger* pode ser configurada. Exemplo: uma assinatura `e25i` representa um elétron isolado com energia transversa superior a 25 GeV. Já a assinatura `2e15i` é a assinatura produzida pelo sistema de filtragem quando dois elétrons isolados e com energia superior a 15 GeV são identificados.
- **Menu**: consiste em uma série de assinaturas. Se uma ou mais assinaturas são satisfeitas, o evento é disparado.
- **Cadeia**: sequência de algoritmos utilizados para ativar uma determinada assinatura.
- **Slice**: um *slice* é a sequência de processamento utilizada para um tipo de partícula (elétron, fótons, múons, etc.) e compreende os três níveis de filtragem (L1, L2 e EF).

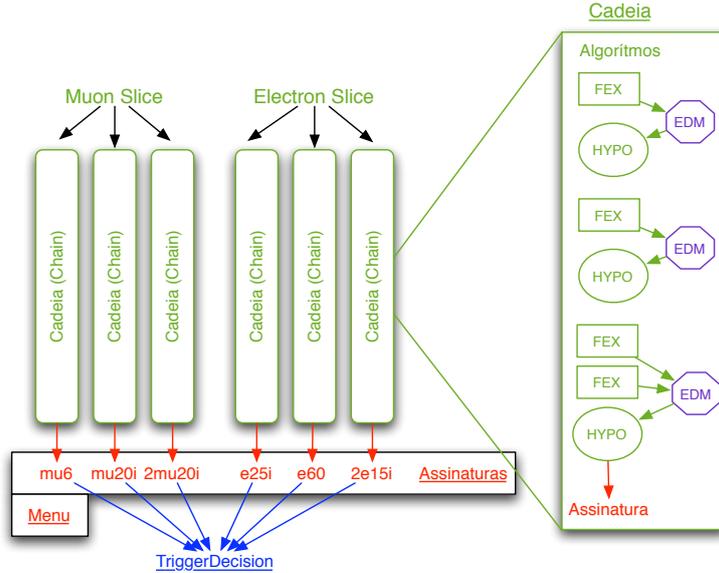


Figura 5.7: Organização do Athena para a filtragem de alto nível do ATLAS.

É apresentado na Figura 5.7 a organização do Athena no que tange a filtragem de alto nível do ATLAS. Podemos observar que um *slice* compreende várias assinaturas contidas em um menu, onde cada uma delas é ativada por uma cadeia de algoritmos. Uma sequência pode ser composta por vários algoritmos de extração de características e de hipóteses. A combinação dos resultados de cada algoritmo de hipótese determinará se a assinatura será ativada ou não. A lista de assinaturas aprovadas e rejeitadas é inserida no *TriggerDecision*, de forma que é possível saber, após a filtragem, quais assinaturas foram ou não aceitas.

Para tornar o desenvolvimento de algoritmos para o sistema de filtragem independente do sistema de fluxo de dados, o Athena implementou camadas de abstração para a comunicação com a L2PU e a PT, de forma que é possível executar os algoritmos *online* em ambiente *offline*, para depois portá-los para o sistema de filtragem do ATLAS.

Durante a execução dos algoritmos de filtragem, é possível salvar em disco o resultado intermediário gerado por cada pacote em um arquivo chamado *NTUPLE*, que pode ser aberto na ferramenta de análise ROOT [66] utilizada no CERN. Além disso, a geração de histogramas de qualquer variável de um dado algoritmo é possível, junto com histogramas com as informações de tempo de execução de uma dada parte do código. Estes histogramas também podem ser visualizados no ROOT.

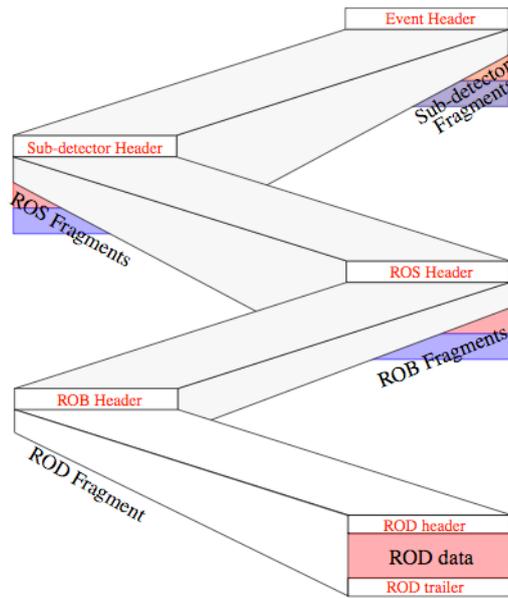


Figura 5.8: Formato geral dos eventos propagados pelo sistema de filtragem de alto nível.

5.3 Formatação dos Dados

A informação produzida pelos detetores do ATLAS precisa de uma formatação padronizada, de forma a facilitar a propagação e o processamento da mesma. Este formato deve atender aos seguintes requisitos:

- Tem que permitir que um evento cresça ou diminua, de acordo com configurações específicas do experimento.
- Não pode ter uma limitação de tamanho para o evento.
- Deve ser baseado em fragmentos, onde um fragmento, na sua apresentação mais baixa é o dado de um ROD.

Par atender estes requisitos, um formato chamado *EFormat* foi desenvolvido [67]. O *EFormat* define a estrutura do dado dentro dos vários estágios do sistema de filtragem de alto nível e do sistema de fluxo de dados. O formato também permite que dados adicionais sejam inseridos, pelo sistema de filtragem, aos dados provenientes do detetor, permitindo que processos possam identificar rapidamente o tipo e a origem de um evento.

O formato geral de um evento completo (*Full Event*) pode ser observado na Figura 5.8. Como se percebe, o evento é composto por fragmentos. Um evento completo é uma união de fragmentos dos subdetetores (calorímetro eletromagnético, detetores de traços, etc.), e um fragmento de um dado subdetetor é um conjunto de fragmentos de um ROS. Já um fragmento de ROS é um conjunto de fragmentos de ROB. Finalmente, cada fragmento de ROB contém apenas um único fragmento de ROD. Cada fragmento contém um cabeçalho e um rodapé, com informações de identificação do evento (procedência, identificação da colisão, etc.) e sobre o seu tamanho, para fácil indexação.

Bibliotecas de leitura e escrita para o *EFormat* estão disponíveis para os desenvolvedores do sistema de filtragem de alto nível do ATLAS, de forma a permitir não só a padronização do formato, bem como o seu acesso.

5.4 Identificação de Elétrons Baseada em Calorimetria

Dado que o sistema de discriminação elétron / jato desenvolvido neste trabalho destina-se ao segundo nível de filtragem do ATLAS, é importante saber como os eventos produzidos pelas colisões no LHC são, inicialmente, filtrados pelo primeiro nível. Adicionalmente, será apresentado o algoritmo padrão do ATLAS para a identificação de elétrons no segundo nível.

5.4.1 Primeiro Nível de Filtragem

A identificação de elétrons no L1 é feita utilizando algoritmos rápidos, dado o pequeno tempo de latência existente neste nível de filtragem. Conseqüentemente, a seleção é feita através de cortes simples, utilizando informações triviais obtidas a partir da leitura das células dos calorímetros. Estas informações são obtidas analisando-se a energia transversa do evento e o perfil lateral e longitudinal do chuveiro produzido.

O algoritmo de filtragem para elétrons está ilustrado na Figura 5.9. Este algoritmo é baseado numa janela contendo 4×4 torres de *trigger*³ em $\eta \times \phi$, tanto para

³Cada torre de *trigger* possui granularidade de $0,1 \times 0,1$ em $\eta \times \phi$ e são produzidas pela soma

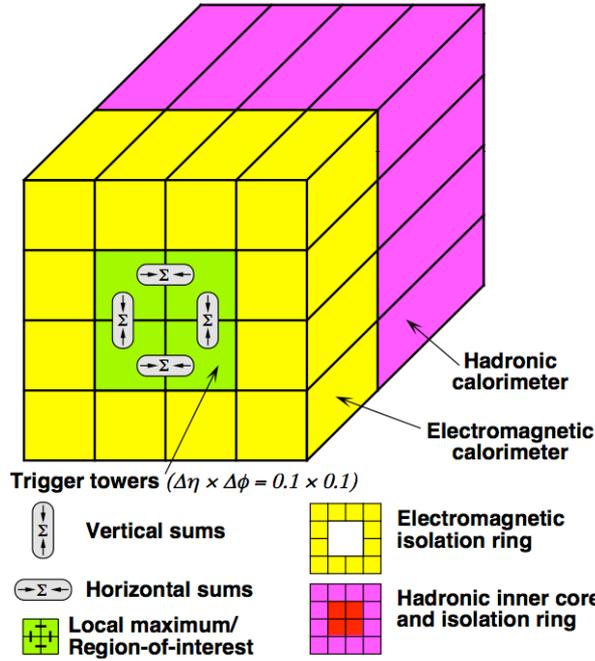


Figura 5.9: Torres de *trigger* utilizadas para a seleção de elétrons no L1 do ATLAS.

o calorímetro eletromagnético como para o hadrônico. A janela de análise percorre todo o calorímetro ($|\eta| < 2,5$) em passos de uma torre, tanto em η quanto em ϕ [68]. Em cada região de análise, as seguintes variáveis são calculadas:

1. A soma das torres (EM e HAD) numa região de 2×2 torres em $\eta \times \phi$ localizadas no centro da janela de análise do L1. Este teste é considerado bem sucedido caso o valor obtido com a soma das torres superar um determinado valor de corte.
2. E_T : quatro *clusters* eletromagnéticos sobrepostos, correspondendo à soma de duas torres. O *cluster* mais energético deve ser maior ou igual a um determinado patamar para este teste ser bem sucedido. É esta variável que determina, para o L1, a energia transversa da RoI.
3. HAD_{Core} (Núcleo hadrônico): soma das quatro torres do calorímetro hadrônico, posicionadas atrás dos *clusters* eletromagnéticos. Este teste será bem sucedido caso esta soma seja menor ou igual a um dado patamar.
4. EM_{Isol} : anel de isolamento eletromagnético, consistindo na soma da energia transversa das 12 torres eletromagnéticas posicionadas ao redor dos quatro

análoga das células do calorímetro.

clusters eletromagnéticos. O teste é considerado bem sucedido caso o valor resultante da soma das 12 torres seja menor ou igual ao patamar de decisão estabelecido para este corte.

5. HAD_{Isol} : anel de isolamento hadrônico, correspondente à soma da energia transversa das 12 torres hadrônicas posicionadas ao redor do núcleo hadrônico. O teste é considerado bem sucedido caso o valor resultante da soma das 12 torres seja menor ou igual ao patamar de decisão estabelecido para este corte.

O primeiro teste serve apenas para determinar uma possível região de interesse (RoI). No caso de cortes sem isolamento, a região será aprovada somente se o segundo teste for bem sucedido. Para cortes com isolamento, a região de análise precisa passar nos 4 últimos cortes.

5.4.2 Segundo Nível de Filtragem

No L2, a identificação de elétrons é feita pelo algoritmo T2Calo [43]. A primeira etapa do T2Calo é refinar a posição em $\eta \times \phi$ da RoI, através do cálculo do baricentro da mesma, empregando, para tal, as células da segunda camada do calorímetro eletromagnético em sua granularidade mais fina. Em seguida, o T2Calo analisa a energia e o perfil lateral e longitudinal do chuveiro produzido, resumindo esta informação em apenas 4 variáveis. Para cada variável, um patamar de corte é estabelecido, dependendo da assinatura de interesse, para determinar se o evento deve, ou não, ser aceito. Por fim, a análise de cada uma das variáveis do T2Calo é sequencial, o que significa que um dado corte, em uma dada variável, só é aplicado aos eventos que foram aprovados pelos cortes anteriores. As 4 variáveis do T2Calo, dispostas na ordem em que são analisadas, são:

1. Razão de Núcleo (R_{core}) \rightarrow Para a 2^a camada eletromagnética, $R_{core} = E_{3 \times 7} / E_{7 \times 7}$, onde $E_{m \times n}$ é a energia depositada em uma região de $m \times n$ células em $\eta \times \phi$ ao redor da célula quente desta camada. Um dado evento será aprovado caso esta variável seja maior ou igual ao patamar de corte estabelecido.
2. Razão de Energia (E_{ratio}) \rightarrow Para a 1^a camada eletromagnética, $E_{ratio} = (E_1 - E_2) / (E_1 + E_2)$, calculada em uma região de $\Delta\eta \times \Delta\phi = 0,125 \times 0,2$

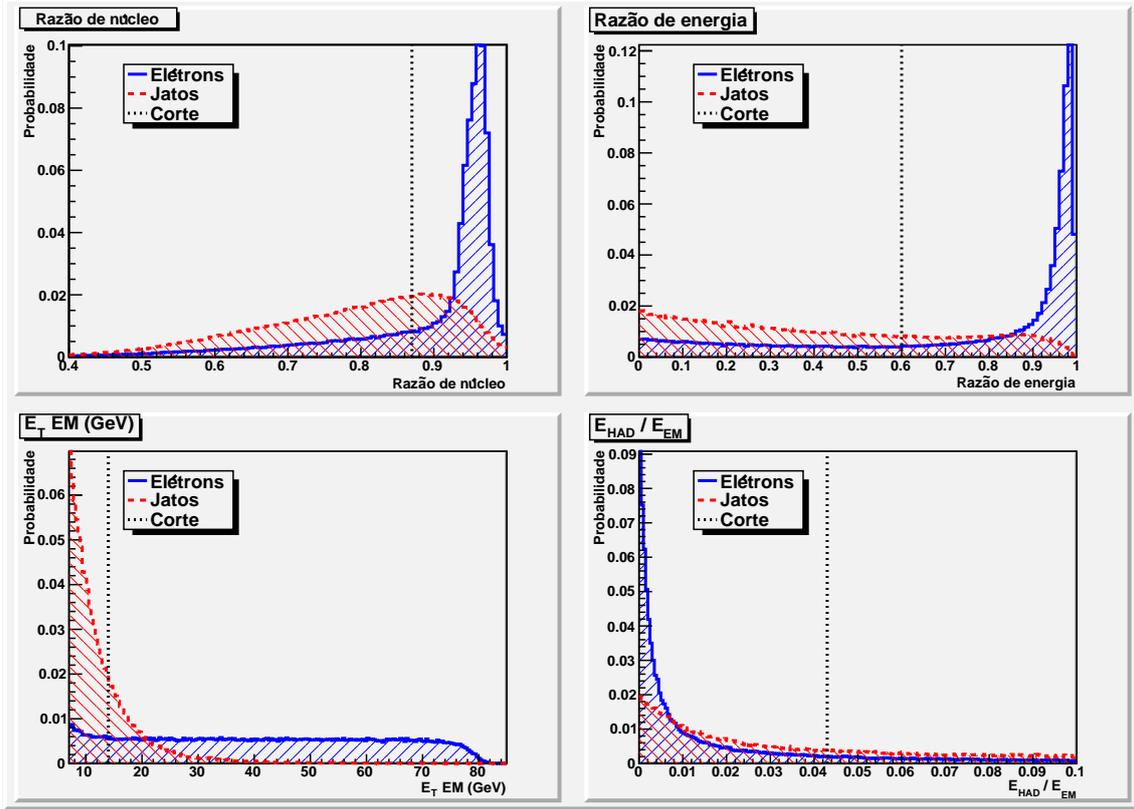


Figura 5.10: Distribuição das 4 variáveis de corte empregadas pelo T2Calo.

ao redor do baricentro da RoI. E_1 e E_2 são, respectivamente, a primeira e a segunda célula de maior energia. Um dado evento será aprovado caso esta variável seja maior ou igual ao patamar de corte estabelecido.

3. Energia Transversa Eletromagnética (E_{TEM}) \rightarrow É a energia transversa total depositada, nas 3 camadas eletromagnéticas, em uma região de 3×7 células em $\eta \times \phi$, centrada na célula quente da 2^a camada eletromagnética. Um dado evento será aprovado caso esta variável seja maior ou igual ao patamar de corte estabelecido.
4. Razão de Energia Eletromagnética e Hadrônica (E_{HAD}/E_{EM}) \rightarrow E_{HAD} é a energia transversa total depositada, nas 3 camadas hadrônicas, em uma janela de $\Delta\eta \times \Delta\phi = 0,2 \times 0,2$ centrada no baricentro da RoI. O corte é aplicado na razão E_{HAD}/E_{EM} , e o evento será aprovado somente se esta razão for menor ou igual ao patamar de corte estabelecido.

Analisando-se a descrição das 4 variáveis produzidas pelo T2Calo, conclui-se que este algoritmo realiza uma análise semelhante ao L1, porém empregando a

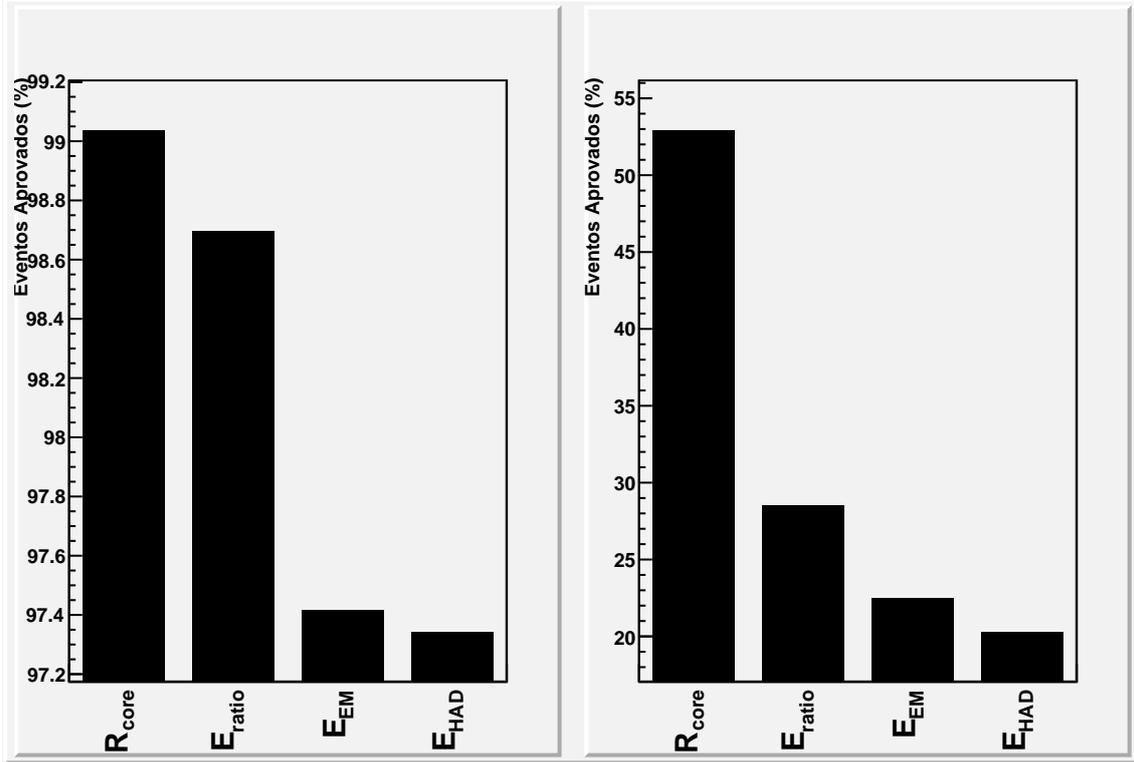


Figura 5.11: Percentual de redução no número de eventos após o corte em cada variável do T2Calo para elétrons (à esquerda) e para jatos (a direita).

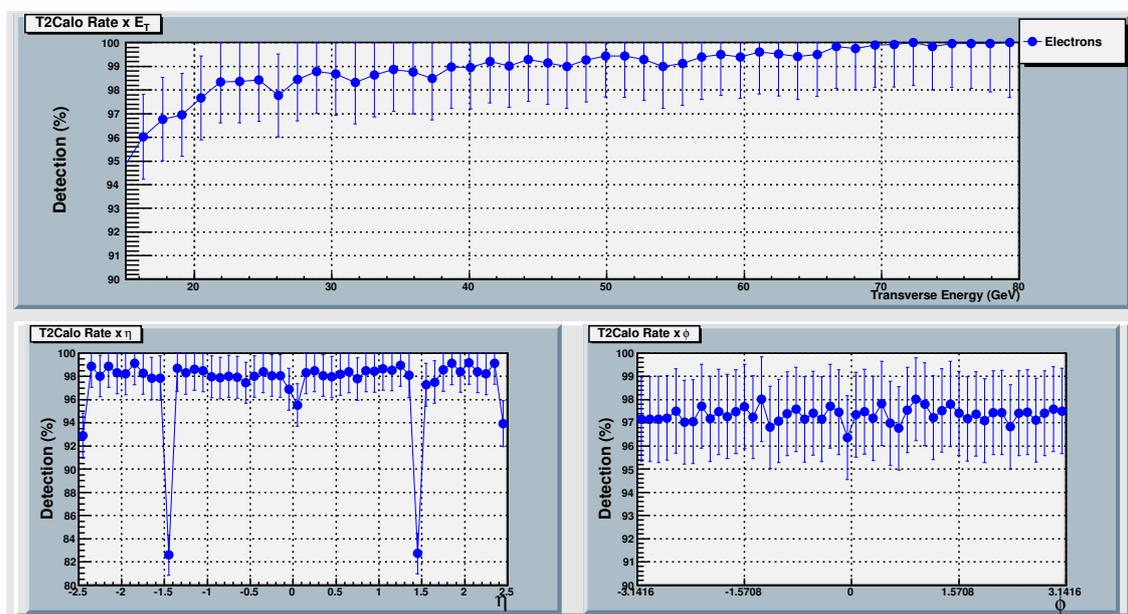
granularidade completa dos detetores. É apresentada, na Figura 5.10, a distribuição de probabilidade de cada variável do T2Calo, para elétrons e jatos pré-filtrados pelo L1 por um corte com isolamento (corte e15i, que será apresentado em detalhes no Capítulo 7). A figura também apresenta os limiares de corte de cada variável. No geral, observa-se, pela posição dos limiares de corte, que o T2Calo foi concebido para ser altamente eficiente, mesmo ao custo de sacrificar o falso alarme. Nota-se, que devido ao corte com isolamento aplicado pelo L1, pouca distinção entre as duas classes pode ser feita analisando-se a razão entre a energia depositada nas seções eletromagnética e hadrônica.

É apresentada, na Figura 5.11 o percentual de redução no número de eventos, obtido quando se efetua o corte em cada uma das 4 variáveis do T2Calo. Deve-se ressaltar que os cortes são sequenciais, de forma que o E_{ratio} , por exemplo, só aplicará seu corte nos eventos que foram aprovados pelo R_{core} , e assim sucessivamente. Observa-se, no caso dos elétrons, que o maior corte é feito pela energia transversa, enquanto que para jatos, o corte mais forte é proporcionado pela razão de energia na EM1 (E_{ratio}). Por fim, nota-se, novamente, a pouca relevância da análise da energia

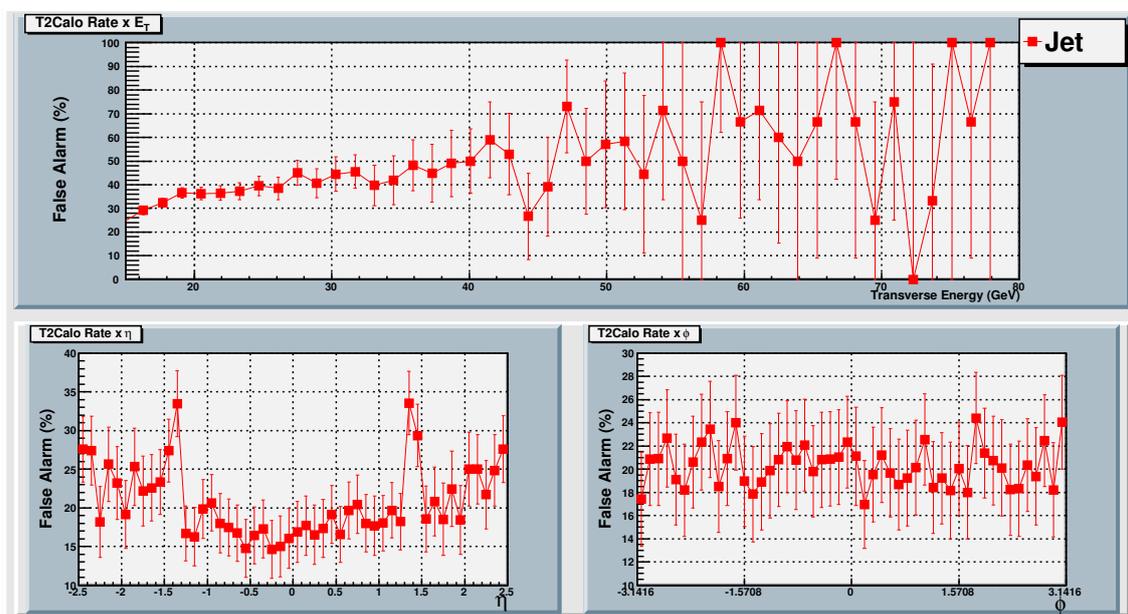
depositada na seção hadrônica para a distinção entre as duas partículas. Ao final dos 4 cortes, o T2Calo provê uma eficiência de detecção de 97,34%, para um falso alarme de 20,3%. Isto resulta em um produto SP⁴ de 87,93%.

Na Figura 5.12, apresenta-se, em função de E_T , η e ϕ , a probabilidade de detecção de elétrons (Figura 5.12a), e o falso alarme (Figura 5.12b). O gráfico da variação da eficiência em função de ϕ mostra um comportamento uniforme da eficiência, para ambas as partículas. Isto está dentro do esperado, dado que o sistema de calorimetria do ATLAS é uniforme ao longo desta coordenada. Por outro lado, a eficiência em função de η mostra, para ambas as classes, uma queda de eficiência nas regiões das fendas em $|\eta| \approx 0$ e $|\eta| \approx 2, 5$. Já para a região de transição entre o barril e a tampa ($|\eta| \approx 1, 45$), a queda na eficiência foi bem mais significativa. No caso particular dos jatos, observa-se, também, um aumento na probabilidade de falso alarme na região da tampa dos calorímetros. Por fim, a eficiência em função da energia transversa mostra, para elétrons, que a eficiência aumenta com a energia do evento, dado que a resolução dos calorímetros escala com a energia da partícula. Para jatos, por outro lado, observa-se o comportamento inverso, já que com o aumento da energia, aumenta-se a probabilidade de produção de π^0 , que, por possuírem componentes com decaimento eletromagnético, acabam por confundir o classificador. No caso dos jatos, a análise da eficiência por energia fica prejudicada para $E_T > 40\text{GeV}$, dada a baixa quantidade de eventos existente nesta região.

⁴O produto SP será apresentado no Capítulo 7.



(a) Elétrons (Probabilidade de Detecção)



(b) Jatos (Falso Alarme)

Figura 5.12: Eficiência global do T2Calo, e a distribuição da eficiência em função de E_T , η e ϕ .

Capítulo 6

Gerenciamento Automático do Sistema de Filtragem do ATLAS

O sistema de filtragem de alto nível do ATLAS é um ambiente em constante evolução. Diariamente, centenas de colaboradores deste ambiente desenvolvem melhorias do sistema, como, por exemplo, parâmetros mais eficientes para a calibração dos detectores, simulações de Monte Carlo mais fidedignas, ou atualizações do *software* desenvolvido para a filtragem de eventos. Adicionalmente, novas técnicas de processamento de sinais precisam ser validadas neste ambiente, para que possam ser incorporadas, com segurança, ao sistema de filtragem e utilizadas durante a operação nominal do LHC. Como consequência, a configuração e execução deste ambiente complexo precisa ser realizada visando cada caso específico de operação (operação nominal, teste de um módulo específico, etc.). Em paralelo, a complexidade do sistema de filtragem do ATLAS exige um longo tempo de aprendizado para que um colaborador esteja minimamente familiarizado com o ambiente.

Esta dinâmica de desenvolvimento do sistema de filtragem do ATLAS seria grandemente beneficiada por mecanismos automáticos de apoio, que permitam a configuração e a execução automáticas do sistema de filtragem, de forma que desenvolvedores possam dedicar-se somente aos seus estudos, abstraindo-se da complexidade de gerenciamento deste sistema. Adicionalmente, esta automatização permitiria que mecanismos de validação automáticos sejam desenvolvidos, propiciando que melhorias do sistema de filtragem possam ser testadas sob diversas condições de operação em um espaço de tempo consideravelmente mais reduzido, e com menor intervenção

humana ao longo do processo.

Este capítulo apresenta os mecanismos de gerenciamento automatizado desenvolvidos para permitir que o sistema de filtragem do ATLAS possa ser configurado e executado de maneira automatizada. Inicialmente, os mecanismos desenvolvidos estavam destinados a gerir apenas o segundo nível de filtragem, visto ser este o local onde as análises desenvolvidas por este trabalho serão implementadas. Entretanto, o sistema desenvolvido provou ser de tal forma versátil que, no âmbito da colaboração ATLAS, foi rapidamente expandido, de forma a abranger todo o sistema de filtragem de alto nível.

Para o desenvolvimento desta tese, as funcionalidades descritas neste capítulo resultaram em uma grande economia de tempo, permitindo que as análises pudessem ser validadas junto ao sistema de filtragem *online* de maneira automatizada, abstraindo-se de detalhes operacionais do TDAQ.

Este capítulo apresenta a seguinte organização. A Seção 6.1 apresentará o serviço de base de dados de configuração existente no sistema de filtragem de alto nível, que fornece, a todos os aplicativos do sistema de filtragem, seus parâmetros de configuração. Em seguida, a Seção 6.2 apresentará o primeiro mecanismo de automação desenvolvido, que destina-se a criar os parâmetros de configuração necessários para operar o *trigger*. Por fim, a Seção 6.3 apresentará o ambiente para execução automática do sistema de filtragem do ATLAS.

6.1 O Servidor de Base de Dados

A descrição do TDAQ, dada no Capítulo 5, deixa clara a alta complexidade deste ambiente. Paralelamente, o TDAQ foi concebido para ser altamente configurável, de forma a atender uma larga faixa de propósitos de operação. Como resultado, para se executar uma determinada topologia do TDAQ, torna-se necessário prover os parâmetros de configuração de cada um dos módulos do TDAQ envolvidos em uma dada execução. Cada módulo contém um determinado número de parâmetros de configuração. Adicionalmente, os dispositivos podem conter relações entre si. Como exemplo, é apresentado, na Figura 6.1, um diagrama resumido com os atributos e relações requeridos para a configuração de uma L2PU. Neste exemplo, é

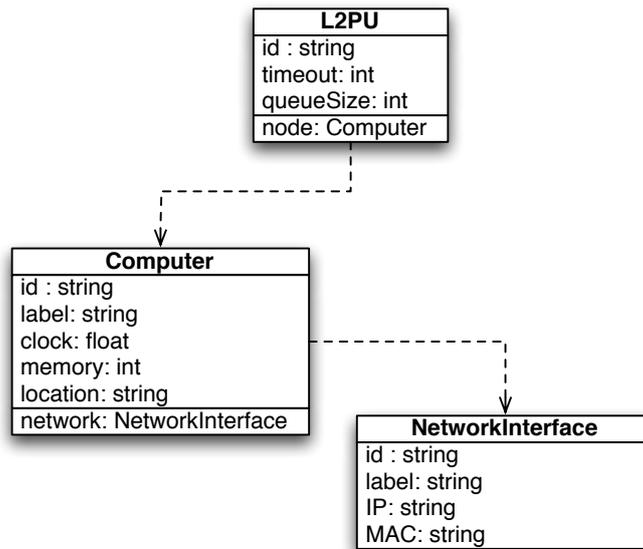


Figura 6.1: Diagrama simplificado com o exemplo da organização dos atributos e relações entre os módulos do TDAQ.

necessário definir, para a L2PU, o seu valor identificador, seu *timeout* e o tamanho da fila. Adicionalmente, precisa-se definir o nó onde a L2PU será executada. Este nó, por sua vez, precisa de seus próprios parâmetros de configuração. No caso da Figura 6.1, a L2PU depende de um computador para ser executada e este computador, por sua vez, necessita de uma ou mais interfaces de rede para sua comunicação. Conseqüentemente, cada módulo (L2PU, ROS, EB, etc.) necessita de vários outros dispositivos, também configuráveis, resultando na necessidade, para executar o TDAQ, de se prover a configuração de milhares de dispositivos distintos. Desta forma, há uma clara demanda por um serviço de base de dados que se responsabilize por armazenar estes parâmetros de configuração e provê-los a todos os aplicativos do TDAQ.

O OKS (*Object Kernel Support*) [69] foi desenvolvido para prover os serviços de configuração do TDAQ. Ele é utilizado para fornecer a descrição total do DAQ e a descrição parcial dos algoritmos de seleção de eventos e do *software* e *hardware* dos detetores. Esta descrição cobre tanto configurações de controle de alto nível (quais partes do TDAQ estarão ativadas em uma dada execução, quando um dado processo deve ser inicializado e em qual nó, configurações de monitoração, configuração da rede, etc.), bem como parâmetros específicos de cada módulo (tamanho de filas,

valores de *timeout*, etc.). Dada a grande quantidade de módulos envolvidos no TDAQ, cada grupo trabalhando em uma dada seção (L2, EF, etc.) é responsável por preparar a configuração de seus respectivos módulos usando as ferramentas do serviço de configuração disponíveis. Durante a inicialização do TDAQ, estes parâmetros são acessados por milhares de aplicativos. Adicionalmente, o OKS é responsável por notificar os aplicativos a respeito de mudanças nos parâmetros de configuração durante a execução do TDAQ. Finalmente, o OKS é capaz de arquivar uma determinada base de dados de configuração para referência futura. Os requisitos em relação à modelagem e acesso aos dados, interface de programação, velocidade de execução, escalabilidade, entre outros, tornam inviável a utilização de base de dados relacionas (Oracle, MySQL, etc.) disponíveis comercialmente [70].

A estrutura de configuração do TDAQ, baseada em atributos e dependências, pode ser representada com clareza através da análise orientada a objetos [71]. Desta forma, no OKS, cada aplicação ou recurso do sistema de filtragem é descrito como uma classe em uma base de dados de *schema*. Esta base contém a descrição de todas as classes, os atributos disponíveis, relações de herança e dependência com outras classes, etc.. Este arquivo de *schema* é utilizado quando uma base de configuração precisa ser criada ou acessada. Adicionalmente, o OKS fornece bibliotecas para a criação ou acesso à base de dados de configuração. Isto é possível através do instanciamento das classes contidas no *schema* e configuração dos valores contidos nos atributos destas classes. A configuração final será lida, no momento da inicialização do sistema de *trigger*, por um aplicativo de controle, que será responsável por inicializar cada um dos aplicativos do sistema de filtragem em seus respectivos nós de processamento. Em seguida, cada aplicação deverá acessar esta base de dados de configuração de forma a configurar parâmetros que digam respeito ao seu funcionamento específico (tamanho de filas, protocolo de comunicação a ser usado, valores de *timeout*, etc.).

Para garantir sua escalabilidade, o sistema de filtragem pode ser dividido, logicamente, em *segmentos*. Cada segmento contém sempre um controlador, que é responsável por gerir somente os aplicativos dentro daquele segmento. Adicionalmente, cada controlador possui um aplicativo (*Remote Database Server* - RDB) responsável por prover uma espécie de *cache* para os valores da base de dados de

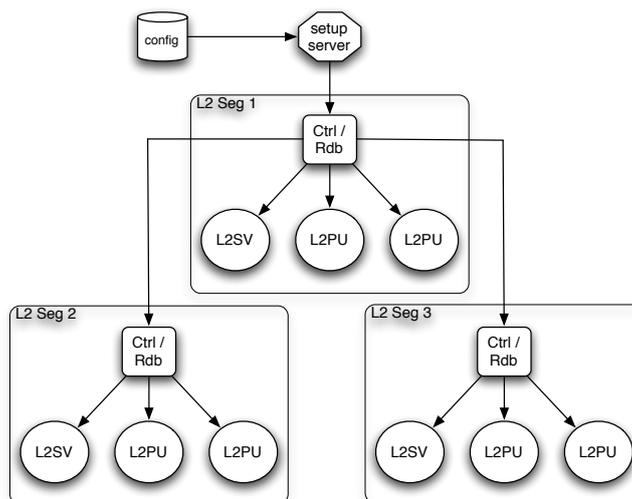


Figura 6.2: Estrutura de controle hierárquico do sistema de filtragem.

configuração, evitando gargalos de acesso à mesma. Múltiplos segmentos podem ser criados e organizados de forma hierárquica, de forma a reduzir a carga de operação por controlador / RDB.

É apresentado, na Figura 6.2, um exemplo de tal abordagem hierárquica para um segmento multi-nível destinado ao segundo nível de filtragem. A aplicação de controle executada no primeiro segmento (mais alto) gerencia apenas as aplicações contidas dentro do seu segmento (L2SV e L2PU), bem como as aplicações de controle existentes nos segmentos de nível hierárquico mais baixo. Paralelamente, cada servidor RDB é visto apenas pelas aplicações contidas no mesmo segmento, além dos servidores RDB existentes nos segmentos filhos. Como resultado desta abordagem multi-nível, o número de aplicativos do TDAQ pode aumentar sem produzir problemas de geração de gargalos de acesso aos controladores ou servidores RDB.

Para a geração da base de dados de configuração, bem como a leitura da mesma, o ambiente OKS oferece interfaces de acesso em C++ e Java. Desta forma, o usuário fica isento dos detalhes de implementação e de localização da base de dados (local ou remota). Entretanto, a tarefa de configurar cada objeto, bem como a relação entre eles e sua organização lógica em segmentos, ainda fica a cargo do usuário, o que representa uma tarefa bastante penosa e delicada, requerendo conhecimento especialista, nem sempre disponível.

6.2 O *PartitionMaker*

Quando uma execução do TDAQ é necessária, muitas considerações precisam ser cuidadosamente analisadas antes da criação da base de dados de configuração. Por exemplo:

- Quais seções (L2, EB ou EF) devem ser ativadas? Se é necessário o filtro de eventos (EF), o construtor de eventos (EB) precisa, obrigatoriamente, estar presente.
- Que módulos, dentro de uma dada seção, devem ser utilizados? Se os dados de análise estão vindo dos detetores, então um RoIB precisa estar ativo. Se os dados são provenientes de simulações de Monte Carlo, o RoIB pode ser descartado.
- Quantas aplicações de cada módulo devem ser empregadas? É inconsistente ter mais supervisores do que unidades de processamento no segundo nível, ou ter mais de um DFM no construtor de eventos (EB).
- Como cada aplicação deve ser configurada? O número de *threads* precisa estar adequado ao número de núcleos de processamento de cada processador. O valor de *timeout* para a resposta do ROS a uma solicitação da L2PU precisa ser menor do que o *timeout* do L2SV para a resposta da L2PU.
- Como a organização em segmentos deve ser feita? Se cada segmento tiver poucos aplicativos, o controlador ficará ocioso a maior parte do tempo, desperdiçando recursos. Caso contrário, um segmento excessivamente grande implicará em sobrecarga dos aplicativos de controle e monitoração, reduzindo a eficiência global do sistema de filtragem.

Os itens acima permitem inferir a complexidade envolvida no processo de se criar os parâmetros de configuração para a execução do TDAQ. Detalhes bastante específicos precisam ser analisados cuidadosamente e o conhecimento exigido para garantir que todos os módulos do TDAQ operem eficientemente torna esta tarefa de configuração quase impossível para usuários com pouco conhecimento sobre a implementação do TDAQ. Milhares de módulos precisam ser configurados e muito

tempo poderá ser perdido na tentativa de configurar todos os módulos corretamente, para uma operação conjunta.

No início do desenvolvimento do sistema de filtragem de alto nível, as partições (nome comumente usado no TDAQ para se referir à base de dados de configurações) eram criadas manualmente, visto que a partição é um arquivo texto contendo os objetos descritos em linguagem bastante similar ao XML [72]. Entretanto, esta solução tornou-se rapidamente inviável devido ao grande número de componentes a serem configurados. Adicionalmente, o conhecimento especialista exigido tornava esta abordagem impossível para usuários novatos.

A primeira abordagem automática para a criação de base de dados de configuração foi baseada em *templates*. Nesta abordagem, o código XML de um objeto de cada classe ficava descrito como um modelo em um arquivo texto. Os parâmetros mais importantes possuíam marcadores neste arquivo de modelos, de tal forma que podiam ser substituídos pelo valor de configuração desejado. A substituição do marcador pelo valor de configuração desejado era feita em um algoritmo simples de “localizar-e-substituir”. Como resultado, o usuário era obrigado a configurar todos os parâmetros variáveis, e qualquer parâmetro não configurável por esta abordagem precisava ser editado manualmente, após a criação da partição. Embora esta abordagem tenha simplificado a criação de base de dados de configuração, ela apresenta ainda várias desvantagens. Por exemplo, embora o número de parâmetros a serem editados tenha diminuído muito, ainda continuava muito elevado. Adicionalmente, como o modelo (*template*) era fixo, qualquer mudança no *schema* podia tornar o modelo inútil até que o desenvolvedor do modelo o atualizasse. Finalmente, esta abordagem não possuía testes de consistência da configuração produzida, sendo útil somente para usuários experientes. Mais tarde, uma camada de processamento foi introduzida no topo desta abordagem, de forma a automatizar a configuração através do processamento de alguns parâmetros de alto nível fornecidos pelo usuário (número de nós por aplicação, número de segmentos, etc.). Esta nova versão resultou em uma interface um pouco mais amigável e simplificada, permitindo seu uso por um número maior de usuários. Entretanto, ainda era considerada confusa, não realizava nenhum teste de consistência dos parâmetros fornecidos pelo usuário, e qualquer mudança na classe de um dado objeto, ou na implementação da base de

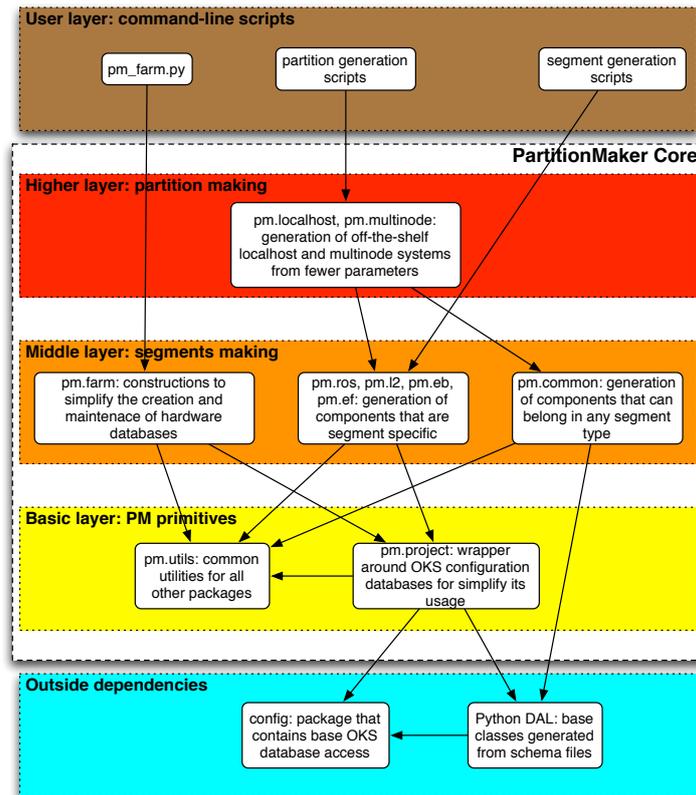


Figura 6.3: Diagrama em blocos do *PartitionMaker*.

dados, inutilizava a ferramenta de configuração até que o desenvolvedor da mesma atualizasse a sua base de *templates*.

Tendo a experiência passada em mente, o *PartitionMaker* foi desenvolvido. Seu diagrama em blocos é apresentado na Figura 6.3. A filosofia deste ambiente é agregar o conhecimento especialista a respeito do sistema de filtragem, de forma que usuários com diferentes níveis de conhecimento sobre o sistema de filtragem possam ser conduzidos com segurança durante o processo de configuração, resultando em execuções otimizadas e minimizando as possibilidades de erros. Por fim, o ambiente deve operar integrado à base de dados OKS, de forma a garantir que mudanças ocorridas na classe de um dado objeto sejam imediatamente reconhecidas pelo *PartitionMaker*.

Ao ser inicializado pelo usuário, o *PartitionMaker* lê a base de dados de *schema* e gera uma representação em *Python* [73] de cada uma das classes existentes. Esta leitura é realizada utilizando *bindings* de C++ para *Python* [74], permitindo que o *PartitionMaker* usufrua dos recursos já implementados na base de dados OKS, além

de isentar o *PartitionMaker* dos detalhes de implementação da base de dados de configuração e *schema*. Após a inicialização, o usuário recorre aos diversos módulos e funções disponíveis para atingir seus objetivos de configuração. De forma a atender uma vasta gama de usuários, com diferentes graus de familiaridade com o sistema de filtragem, uma abordagem multi-camada foi utilizada.

A camada mais baixa (*Primitivas do PM*, ou *Camada de Componentes*) é responsável pelas funcionalidades básicas do *PartitionMaker*. Ela contém a interface responsável por abstrair, do usuário, os detalhes de implementação da base de dados de configuração, sendo utilizada para a leitura e escrita destas. Esta camada também provê as regras para a representação das classes existentes no *schema* em *Python*. Finalmente, esta camada oferece mecanismos para a busca e modificação de módulos existentes em uma base de dados de configuração.

A segunda camada (*Camada de Segmentos*) responsabiliza-se por agrupar módulos na forma de segmentos com significado lógico para o sistema de filtragem. Os módulos desta camada são encarregados de criar segmentos para o TDAQ (L2, EB, etc.). É de responsabilidade desta camada assegurar que as relações entre as aplicações dentro de um mesmo segmento estejam corretas, e que as aplicações contidas no mesmo apresentem relações entre si (por exemplo, evitando que uma aplicação do filtro de eventos esteja presente em um segmento destinado ao segundo nível).

A última camada (*Camada de Partição*) se encarrega de agrupar os recursos das camadas mais baixas em uma base final de configuração. Esta camada recebe apenas alguns parâmetros de alto nível e retorna uma base de configuração pronta para executar o sistema de filtragem. Nesta camada, é verificada se a relação entre os módulos produzidos pelas camadas mais baixas está correta, para que os mesmos operem em harmonia.

No topo de todas estas camadas, existe a *Camada de Usuário*. Ela é composta por um conjunto de *scripts* operados por linha de comando, que permitem a rápida criação de base de dados de configuração, baseada em valores *default*. Adicionalmente, esta camada permite que usuários possam desenvolver seus próprios *scripts*, ajudando-os a, rapidamente, cobrir casos mais específicos, não abordados pela implementação padrão.

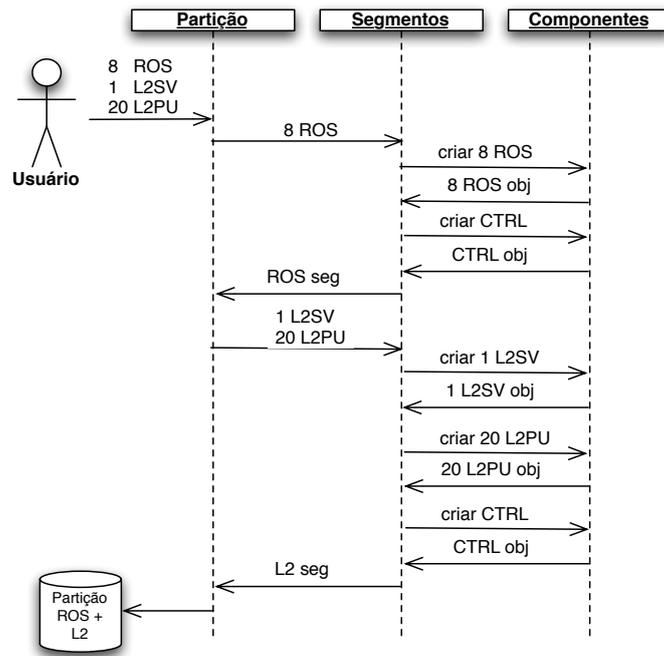


Figura 6.4: Exemplo de fluxo de geração de uma partição.

Com esta abordagem multi-camada, usuários com experiências bastante distintas em relação ao sistema de filtragem podem alcançar rapidamente seus objetivos de configuração. Usuários mais inexperientes podem trabalhar apenas com os *scripts* de linha de comando, fornecendo alguns poucos parâmetros gerais (número de processadores a serem utilizados, quais seções devem ser executadas, etc.). Valores mais específicos (*timeout* de execução, tamanho de filas, protocolo de comunicação, organização em segmentos, etc.) são automaticamente calculados, graças ao conhecimento especialista agregado. Já usuários mais experientes, para atenderem casos de uso mais específicos, podem recorrer às camadas mais baixas do sistema, com o custo de serem capazes de saber o impacto (negativo ou positivo) de cada parâmetro para o sistema de filtragem. Usuários podem, inclusive, combinar recursos de várias camadas, por exemplo, gerando uma configuração padrão com a camada mais alta, e com recursos da camada mais baixa, alterar seus objetos e segmentos de acordo com suas necessidades especiais.

É apresentado, na Figura 6.4, um exemplo simplificado do fluxo de mensagens para a criação de uma partição contendo 8 ROS, além do L2 contendo 1 L2SV e 20 L2PU. No exemplo, o usuário trabalha somente com um *script* de linha de comando. Ao especificar somente o número de componentes desejados, a camada



Figura 6.5: Exemplo de geração de uma partição.

de partição dispara mensagens para a camada de segmentos, de forma que sejam criados os segmentos para os ROS e L2. A camada de segmentos, por sua vez, ativa a camada de componentes, de forma que cada um dos objetos necessários sejam criados e retornados à camada de segmentos. Em seguida, a camada de segmentos agrupa tais componentes de maneira coerente à sua função, e os segmentos gerados são retornados para a camada de partição, para que sejam conectados e finalmente retornados ao usuário, finalizando o processo de criação da base de dados de configuração.

Outra etapa importante no processo de configuração é selecionar os nós de processamento a serem utilizados por cada aplicação. Para tal, um módulo especial permite rastrear um conjunto de máquinas de forma a analisar a propriedade destas (velocidade de *clock*, quantidade de memória, interfaces de rede, etc.), para melhor definir quais aplicações devem rodar em quais máquinas. A busca por nós é feita em paralelo, através da utilização de várias *threads* [60] de execução, usando a estrutura de rede disponível. Isto resulta em tempos de busca bastante reduzidos, da ordem de poucas dezenas de segundos, para um conjunto de várias centenas de máquinas.

Por ser implementado em *Python*, o *PartitionMaker* pode usufruir dos recursos bastante numerosos desta linguagem. Como consequência, um ambiente integrado de desenvolvimento está disponível, permitindo rápida prototipagem de base de dados de configuração, conforme o exemplo na Figura 6.5 demonstra. Ao inicializar o ambiente integrado, o usuário acessa as funcionalidades do sistema. No exemplo, deseja-se configurar manualmente um nó de execução (`my_node`) contendo uma interface de rede (`my_interface`), usando, neste caso, a *Camada de Componentes*. Ao final da configuração, os objetos criados em *Python* são exportados para o formato utilizado pelo OKS através da função `quickGenerate`, cujo resultado aparece ao lado direito da Figura 6.5.

A facilidade da linguagem *Python*, aliada ao ambiente integrado de desenvolvimento, permite que *plugins* possam ser facilmente desenvolvidos para o *PartitionMaker*, expandindo consideravelmente a capacidade do trabalho desenvolvido. Por fim, como o ambiente integrado aceita comandos, tanto manualmente inseridos, bem como oriundos de um arquivo texto, *scripts* de configuração podem ser escritos com facilidade, apoiando a execução de testes automáticos do sistema de filtragem do ATLAS, quando se deseja observar o comportamento deste sistema sob diversas condições de operação (número de processadores, níveis de filtragem considerados, etc.).

A abordagem utilizada para a concepção do *PartitionMaker* resultou num claro aumento da produtividade dos desenvolvedores e operadores do sistema de filtragem do ATLAS. Antes, era necessária a presença de especialistas para garantir a correta configuração do sistema de filtragem. Com este conhecimento especialista embutido no *PartitionMaker*, os usuários ficam mais independentes durante o processo de configuração, podendo focar seus esforços em suas pesquisas específicas. Isto resulta, também, em ganhos de produtividade para os técnicos especialistas, visto que minimiza-se a necessidade destes interromperem suas atividades para apoiar usuários menos experientes.

Outro resultado obtido foi a considerável diminuição do número de execuções mal sucedidas para os testes do sistema de filtragem do ATLAS. Com o *PartitionMaker* identificando e notificando, automaticamente, possíveis erros durante a configuração, possíveis falhas puderam ser identificadas antes da execução do sistema de filtragem,

evitando-se a interrupção da operação do experimento.

6.3 Execução Automática do Sistema de Filtragem

O sistema de filtragem do ATLAS utiliza uma máquina de estados finita para conduzir seus componentes para o estado de execução [75]. Este controle é comandado por aplicações especializadas, que formam uma árvore de controle estruturada. Comandos são passados pelo usuário através de uma interface gráfica para o ponto mais alto da árvore de controle e são, então, propagados para as aplicações de nível hierárquico mais baixo, de maneira ordenada. Abaixo, estão citados os principais estados de transição que o usuário deve seguir até o sistema estar pronto para a coleta de dados.

1. **Inicialização:** neste ponto, a base de configurações é lida e os aplicativos de controle posicionados no nível mais alto são inicializados. Em seguida, todos os aplicativos ligados a este controlador são inicializados, bem como todos os controladores do nível imediatamente abaixo. Por sua vez, estes controladores inicializam suas aplicações, numa reação em cadeia, até que todo o sistema de filtragem esteja ativado. Neste ponto, todos os servidores RDB também se encontram ativos, para proverem os parâmetros de configuração na etapa seguinte. Todas as aplicações são inicializadas nos nós de processamento destinados a eles na base de configurações.
2. **Configuração:** durante esta fase, os aplicativos irão acessar seus parâmetros de configuração dos seus respectivos servidores RDB. Neste ponto, a infraestrutura do TDAQ está pronta para iniciar sua operação.
3. **Execução:** nesta etapa, o sistema de filtragem acessa os eventos que interagiram com os detetores do ATLAS, ou os arquivos de simulação de Monte Carlo, e realiza a filtragem propriamente dita. Durante a execução, informações da operação de toda a infraestrutura são amostradas e utilizadas para a produção de histogramas e gráficos *online*, de modo a serem analisados pelos operadores do sistema de filtragem, ou por mecanismos automáticos de monitoração.

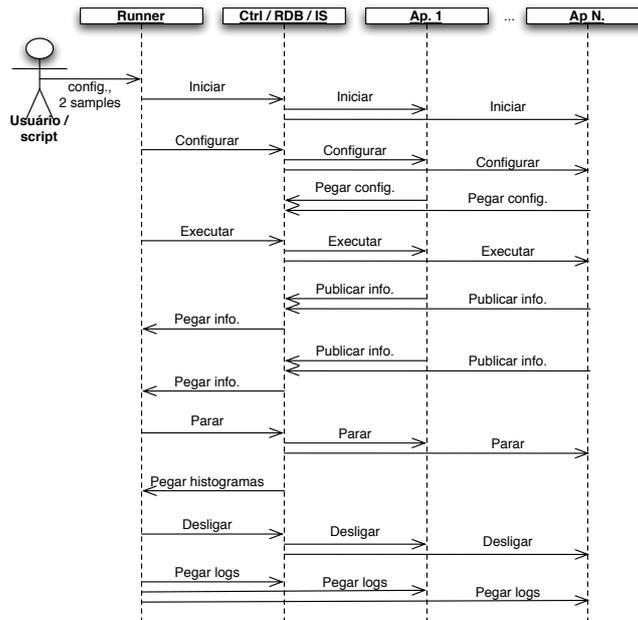


Figura 6.6: Exemplo do fluxo de processamento do sistema de execução automática do TDAQ.

Nesta etapa, arquivos de *log* também são produzidos, por cada aplicação, para serem analisados pelos desenvolvedores em caso de falhas de execução de um determinado módulo. Este estado é mantido até que a ordem de interrupção do sistema de filtragem seja fornecida pelos operadores.

Para a interrupção do sistema de filtragem, os mesmos passos acima são executados, em ordem reversa, até que o sistema de filtragem se encontre novamente desligado.

Embora ativar manualmente cada um dos passos descritos acima seja razoável, durante a operação nominal do experimento, esta tarefa tende a ser bastante tediosa quando é necessário executar o sistema de filtragem muitas vezes, como é o caso de testes de validação de novas versões do TDAQ e de novos *hardwares* incorporados ao projeto [76]. Adicionalmente, a ativação manual do sistema de filtragem impossibilita que testes automáticos sejam realizados.

Para suprir esta necessidade de execução automatizada do sistema de filtragem, o *Runner* foi desenvolvido. Seu principal objetivo é prover uma maneira automatizada de executar o TDAQ, gerindo automaticamente a máquina de estados deste sistema, e, ao final da execução do mesmo, retornar ao usuário as informações de

monitoração e *logs* de execução, além de um relatório com a análise das informações de monitoração, caso este seja desejado pelo usuário.

É apresentado, na Figura 6.6, um exemplo generalizado do fluxo de comandos do *Runner*. Neste exemplo, o usuário (um *script* de execução, por exemplo) provê a base de dados de configuração e requisita, ao *Runner*, a execução do TDAQ por tempo suficiente para que duas amostras de informações de monitoração possam ser adquiridas.

Primeiramente, o *Runner* envia a mensagem para o controlador de mais alto nível do TDAQ, para que o mesmo inicialize a infraestrutura do sistema de filtragem. Este controlador, por sua vez, propaga a mensagem para a inicialização. Em seguida, de maneira análoga, o comando para a configuração do TDAQ é propagado, e cada módulo acessa seus parâmetros de configuração do servidor RDB a que está conectado. Na sequência, o sistema de filtragem é inicializado, e cada aplicativo publica suas informações de monitoração no servidor IS ao qual está conectado, e este produz, também, os histogramas *online* com a estatística obtida com a execução do TDAQ. Em paralelo, o *Runner* acessa este servidor de IS para recolher as informações já publicadas. Após a aquisição de um determinado número de amostras de monitoração (2, no caso do exemplo da Figura 6.6), o *Runner* envia a instrução para a interrupção da execução do sistema de filtragem, sendo esta propagada por todo o TDAQ. Após a interrupção, os histogramas gerados são copiados de cada servidor IS para a máquina onde o *Runner* está sendo executado. Em seguida, o *Runner* ordena a finalização de todos os aplicativos, e, após o término dos mesmos, se conecta remotamente a cada um dos nós utilizados para a execução do TDAQ, recolhendo os arquivos de *log* gerados durante o processo. Ao final, as variáveis de monitoração, histogramas *online* e *logs* de execução estão todos concentrados na máquina do usuário e disponíveis para análise *offline*.

O *Runner* foi desenvolvido como um conjunto de módulos em *Python*. Desta forma, a mesma IDE e linguagem de sintaxe disponíveis para o *PartitionMaker* estão, também, disponíveis para este ambiente. Conseqüentemente, *plugins* e *scripts* de configuração podem ser facilmente desenvolvidos para este ambiente.

Ao combinarem-se os recursos do *Runner* com o *PartitionMaker*, aliados com ferramentas de análise com interface em *Python*, como o *ROOT* [77], obtém-se a

automatização total da execução do sistema de filtragem do ATLAS, permitindo o desenvolvimento de mecanismos de validação mais eficientes, contribuindo para que os desenvolvedores do TDAQ possam se abstrair de detalhes do processo de execução do TDAQ, deixando estes usuários focados exclusivamente no desenvolvimento de módulos de sua competência.

Capítulo 7

Caracterização dos Dados

Simulados e Anelamento para a Calorimetria

Este capítulo visa apresentar o conjunto de dados simulados adotado para o desenvolvimento deste trabalho. O objetivo é compreender as características gerais dos sinais gerados por simulação, bem como o processo de interação destes eventos com o sistema de calorimetria do ATLAS. Adicionalmente, será apresentado o pré-processamento baseado em anéis topológicos, empregado para reduzir e uniformizar a dimensão do espaço de entrada de dados. Uma vez que os anéis são produzidos, estes serão a base usada para o desenvolvimento dos algoritmos propostos. Consequentemente, é de grande importância que as características físicas destes anéis sejam estudadas para que as técnicas de pré-processamento adicionais possam ser aplicadas para a seleção de características relevantes ao processo de discriminação.

7.1 Geração dos Eventos

Os eventos utilizados neste trabalho são oriundos de simulações de Monte Carlo produzidas pela colaboração ATLAS utilizando o *Pythia* (produção das colisões) e o *Geant* (interação com os calorímetros) da versão 14.2.10 do Athena (veja a Seção 5.2.4). Estes dados representam a informação extraída do *Readout Driver* conectado a cada canal de leitura do ATLAS. Como eventos de sinal, elétrons iso-

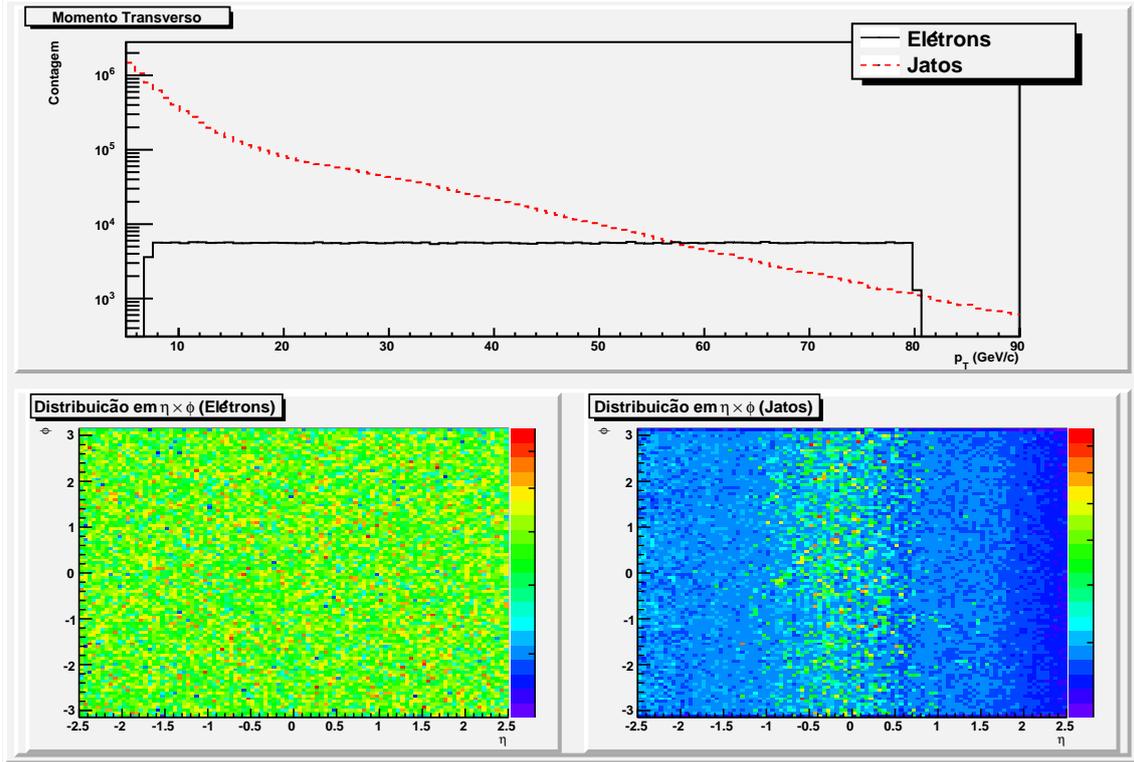


Figura 7.1: Distribuição do momento transverso, η e ϕ dos eventos contidos nas simulações de Monte Carlo utilizadas.

lados distribuídos uniformemente em $7 \leq E_T \leq 80$ GeV foram produzidos. Como amostras de ruído de fundo, dijatos contendo pelo menos um componente eletromagnético, com $E_T > 17$ GeV, foram utilizados.

É apresentada, na Figura 7.1 a distribuição do momento transverso (p_T)¹, η e ϕ dos eventos produzidos nas simulações de Monte Carlo empregadas. Observa-se que o p_T cobre, para ambas as partículas, toda a região entre 7 e 80 GeV. A distribuição de eventos no plano $\eta \times \phi$ também mostra que os eventos cobrem toda a região de interesse neste plano.

7.1.1 Interação com o Sistema de Calorimetria

As Figuras 7.2 e 7.3 apresentam, como exemplo, o perfil de deposição simulada de energia para um elétron e um jato, respectivamente, nas 4 camadas eletromagnéticas e 3 camadas hadrônicas do ATLAS. Para estes 2 eventos típicos, percebe-se clara-

¹A simulação de Monte Carlo provê, para cada evento, apenas o seu momento. A energia pode ser obtida através da relação $E^2 = p^2 + m^2$, onde m é a massa da partícula. No caso dos elétrons, dada a pequena massa dos mesmos, é válido considerar $p \approx E$.

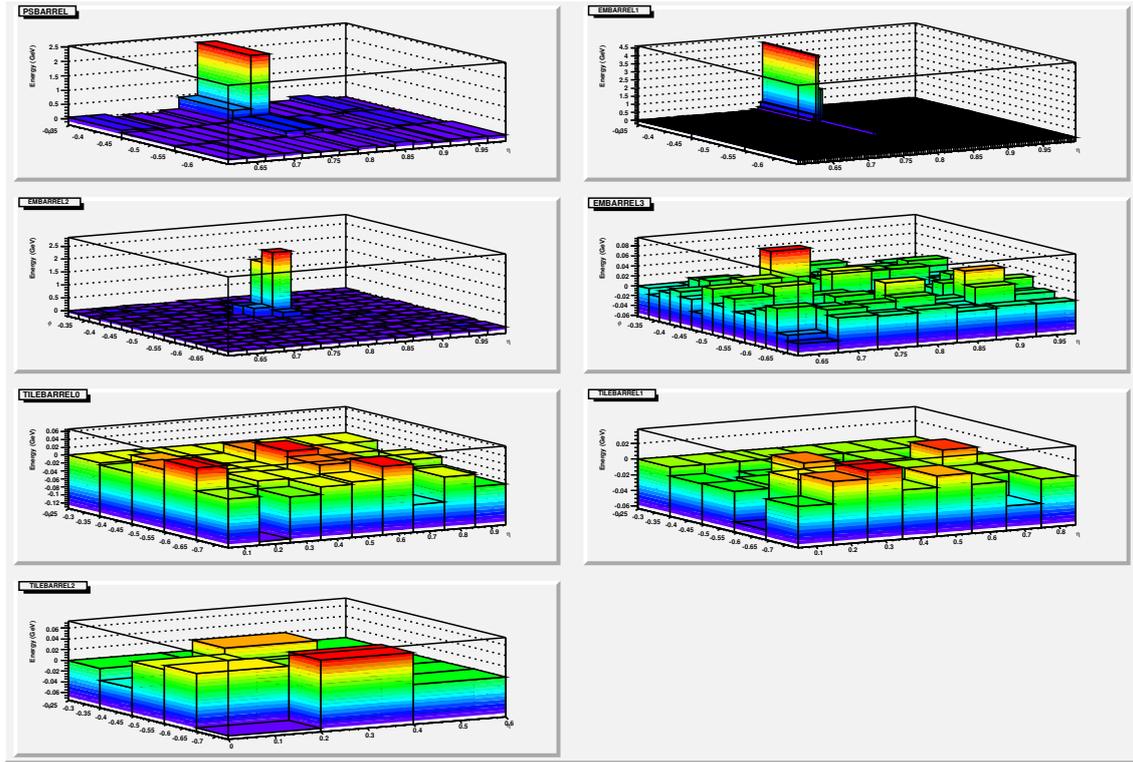


Figura 7.2: Deposição de energia pelas camadas dos calorímetros EM e HAD para um elétron típico.

mente as diferenças existentes entre os chuveiros eletromagnéticos e hadrônicos, tal como descrito no Capítulo 3. O *pre-shower* amostra consideravelmente mais energia para elétrons. Adicionalmente, percebe-se claramente que o chuveiro hadrônico apresenta, em geral, um perfil lateral mais largo, enquanto que o elétron deposita a sua energia de maneira mais pontual. A análise do perfil longitudinal do chuveiros eletromagnéticos e hadrônicos obtidos com estes dois eventos mostra que apenas o chuveiro hadrônico atingiu a seção hadrônica do sistema de calorimetria, enquanto que o elétron foi totalmente contido pela seção eletromagnética. Por fim, a baixa deposição de energia na EM3, tanto para o elétron, como para o jato, é razoável, visto que esta camada só existe para conter o chuveiro eletromagnético de partículas de energia muito elevada (*tail catcher*).

Na Figura 7.4, são apresentados os histogramas de energia transversa (vide Seção 3.3) para as regiões de interesse (RoI), após a interação com os calorímetros do ATLAS, além dos valores de η e ϕ do centro de cada RoI. Para a distribuição de energia, consideramos apenas o espectro de energia na faixa de $7 \leq E_T \leq 80$ GeV, visto que é nesta região que se encontram as principais assinaturas de eventos

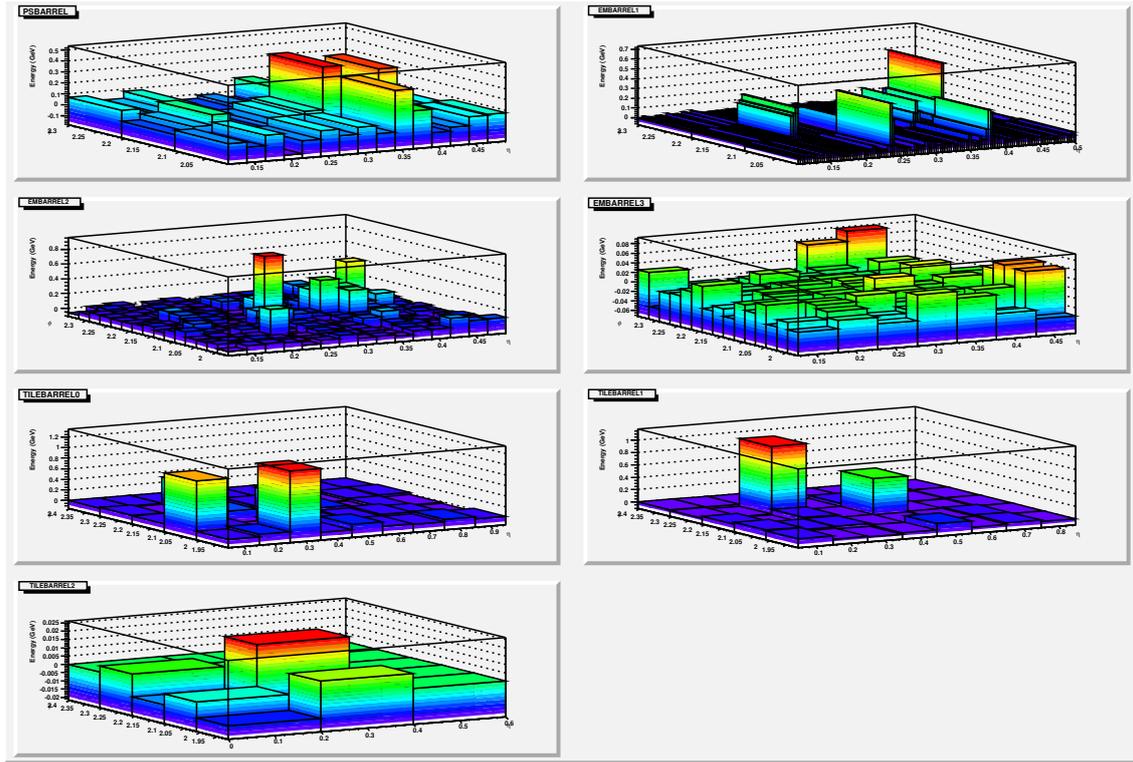
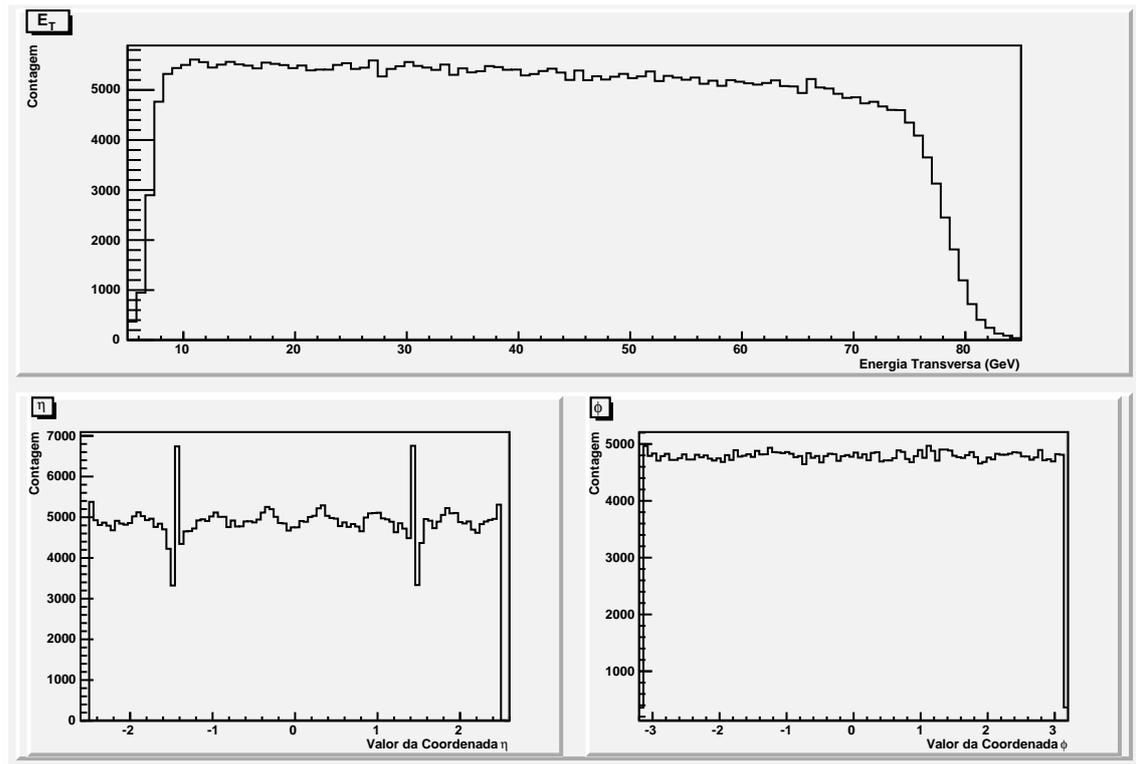


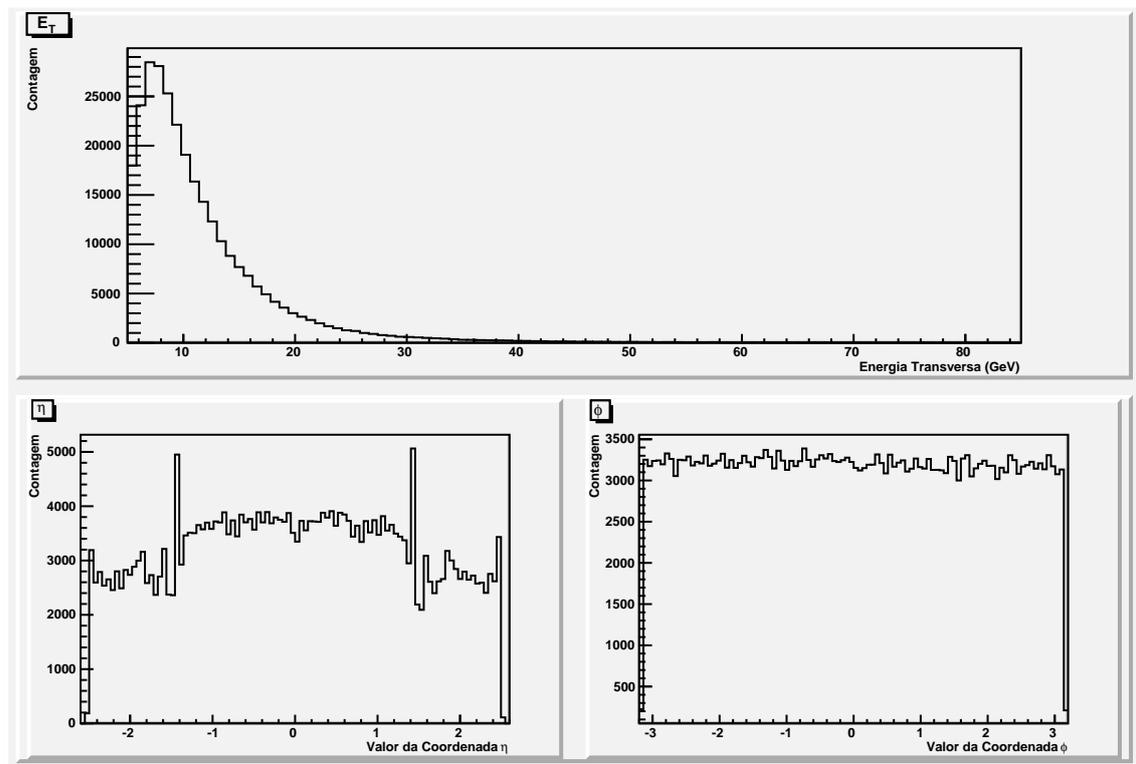
Figura 7.3: Deposição de energia pelas camadas dos calorímetros EM e HAD para um jato típico.

eletromagnéticos. Comparando esta distribuição de energia com a energia original dos eventos (apresentada na Figura 7.1), nota-se, no caso particular dos elétrons, uma pequena quantidade de eventos com $E_T > 80$ GeV. O motivo desta aparente discrepância reside no processo de calibração adotado para a estimação da energia de partículas interagindo com a calorimetria do ATLAS. Esta calibração resulta de um processo estatístico, que, na média, permite estimar precisamente a energia dos eventos. Entretanto, esta calibração possui um desvio padrão associado, o que pode resultar em valores um pouco divergentes do ideal.

Para a distribuição em η , a análise desconsiderou a parte interna da tampa e o *forward calorimeter* ($|\eta| > 2,5$), visto que a probabilidade de eventos interessantes serem oriundos desta região é bastante reduzida. Os picos em $|\eta| \approx 1,45$ correspondem às últimas células (em η) do barril da EM2, que são maiores ($0,075 \times 0,025$ em $\eta \times \phi$) nesta região (veja a Tabela 3.1). No caso da distribuição em ϕ , observa-se que as células cobrem a faixa entre $\pm\pi$ de maneira bastante uniforme, como é esperado, dada a cobertura completa em ϕ que os calorímetros do ATLAS provêm.



(a) Elétrons



(b) Jatos

Figura 7.4: Distribuição da informação proveniente dos calorímetros para cada tipo de partícula.

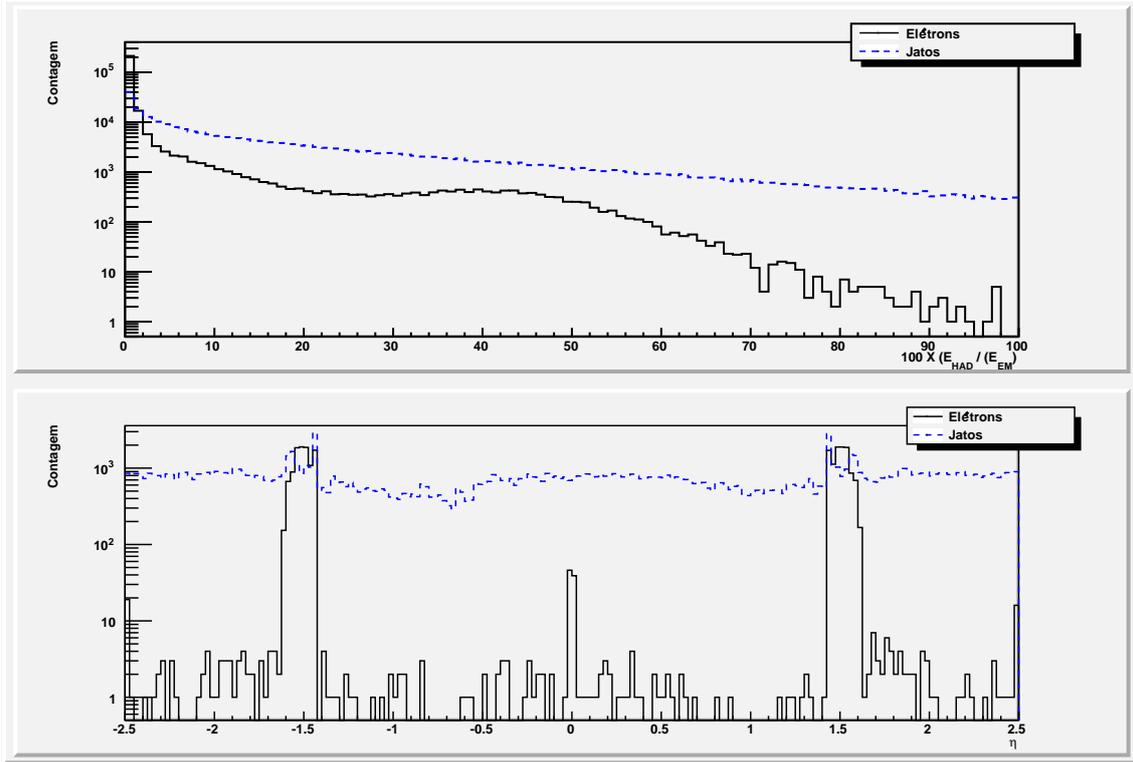


Figura 7.5: Razão entre a deposição de energia na seção HAD e EM (em cima) e a distribuição, em η dos eventos com razão $E_{HAD}/E_{EM} > 10\%$ (embaixo).

Outra análise importante é o vazamento de energia para a seção hadrônica. É apresentada, na Figura 7.5, parte superior, a distribuição da razão entre a quantidade de energia depositada na seção hadrônica e a energia depositada na seção eletromagnética. Como esperado, esta razão tende a ser maior para os jatos.

Na parte inferior da Figura 7.5, observa-se a distribuição da posição em η para todos os eventos com $E_{HAD}/E_{EM} > 10\%$. Como esperado, esta distribuição é uniforme para o conjunto de jatos, visto que é esperado que atinjam a seção hadrônica. Já para os elétrons, podem-se observar três picos. Primeiramente, temos a concentração em $|\eta| \approx 0$, que é resultado da existência de uma fenda, na região $|\eta| < 0.015$, existente apenas no calorímetro eletromagnético, de tal forma que a absorção de energia nesta região, para o calorímetro eletromagnético fica reduzida. Também observa-se uma quantidade maior de eventos em $|\eta| \approx 2, 5$, uma vez que existe outra fenda nesta região, devido à transição entre o anel externo e interno da tampa do calorímetro eletromagnético (vide Figura 3.10). Por fim, sabe-se [78] que o vazamento de energia para a seção hadrônica tende a aumentar com a energia, mesmo para elétrons, o que justifica os pouquíssimos elétrons observados fora das zonas

correspondentes às fendas².

A última região, que concentra a maior parte dos eventos, e que merece maior atenção é a região com $1,475 \leq |\eta| \leq 1,6$, correspondente à zona de transição entre o barril e a tampa do calorímetro eletromagnético (vide Figura 3.10). É apresentada, na Figura 7.6, a quantidade de energia transversa absorvida pelas seções eletromagnética (gráfico na parte superior) e hadrônica (gráfico no centro da figura), em função de $|\eta|$, para elétrons. Na parte inferior da Figura 7.6, apresenta-se a soma das energias transversas depositadas nas seções eletromagnéticas e hadrônica. Analisando estes 3 gráficos, visualiza-se claramente, para esta fenda, a perda de energia na seção eletromagnética, pois nesta zona, um elétron incidindo encontra pelo seu caminho uma quantidade menor de material passivo no calorímetro eletromagnético, de tal modo que parte do chuveiro eletromagnético se desenvolvendo na seção hadrônica, e, conseqüentemente, há uma maior deposição de energia nesta seção. Entretanto, ao somar-se a energia de ambas as camadas, nota-se que, no geral, pouca energia deixa de ser absorvida pelo sistema de calorimetria do ATLAS. A pequena perda de energia ainda observada, no gráfico na parte inferior da Figura 7.6, representa a energia perdida através da interação de elétrons com o material morto (cabos, tubos com material criogênico, etc.) posicionado à frente da tampa do calorímetro eletromagnético nesta região (veja a Figura 3.10).

7.1.2 Filtragem pelo Primeiro Nível

Tendo em vista que a pesquisa desenvolvida destina-se ao L2 do ATLAS, torna-se necessário propagar os eventos simulados pelo primeiro nível de filtragem. Durante a fase de desenvolvimento do ATLAS, é de suma importância conhecer bem os sinais produzidos pelos seus detetores. Como o sistema de filtragem *online*, dada a sua concepção, não pode desfazer uma rejeição, é de grande relevância que o processamento destes eventos esteja sendo feito como esperado, sem a introdução de tendências estatísticas. Desta forma, para a validação do sistema de filtragem, antes do início de sua operação nominal, cortes mais brandos no L1 são adotados, visando

²De fato, para $E_T > 90$ GeV, o T2Calo não mais aplica o corte baseado na deposição de energia na seção hadrônica, dado que o vazamento da energia de elétrons para esta seção pode prejudicar esta análise.

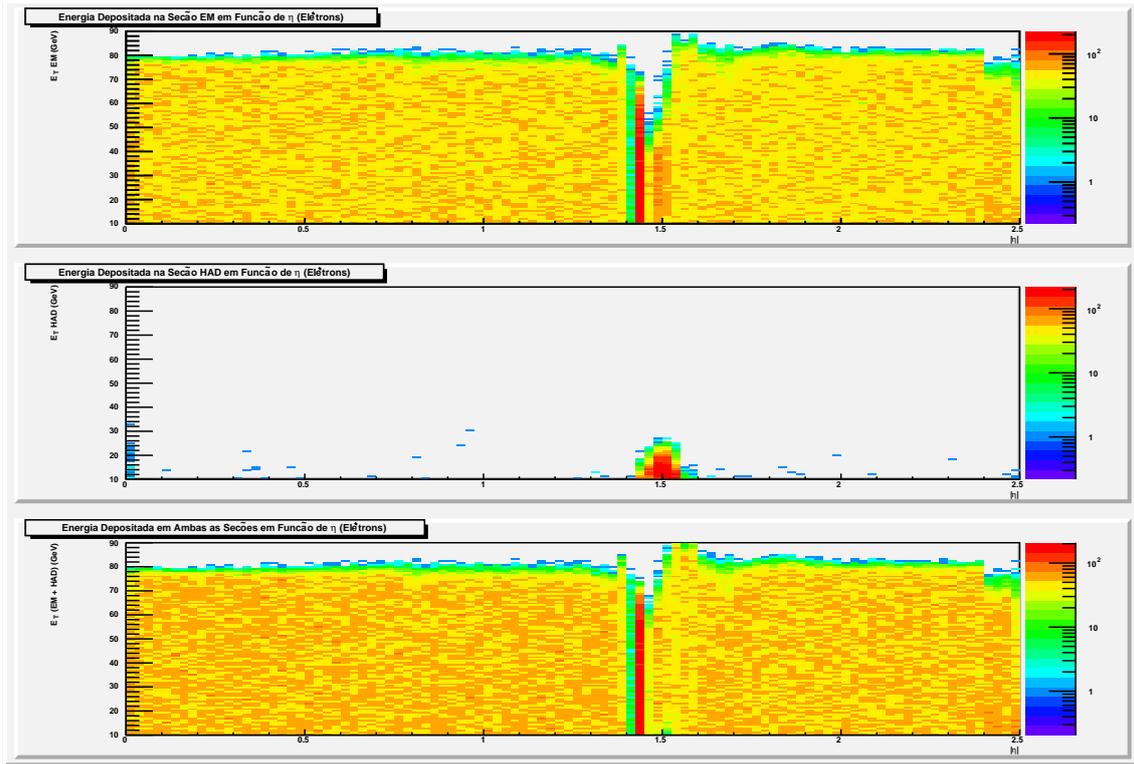


Figura 7.6: Absorção de elétrons pelos calorímetros eletromagnéticos e hadrônicos para o conjunto de elétrons.

armazenar um conjunto maior de eventos que representem uma gama maior dos processos produzidos pelas colisões no LHC. Uma vez que os detetores e o sistema de filtragem estão bem depurados e conhecidos pela colaboração, cortes mais rigorosos podem ser empregados para a operação nominal do L1.

Neste âmbito, no desenvolvimento deste trabalho, o primeiro nível (veja a Seção 5.4.1) foi executado com 2 cortes distintos (vide Tabela 7.1), conforme o menu de *trigger* do ATLAS. O primeiro corte (e10) é um corte sem isolamento, que aprovará qualquer evento com energia transversa maior do que 7 GeV. O segundo corte (e15i) utiliza isolamento, e um limiar inferior de energia mais alto do que o e10, sendo mais adequado a testes visando a operação nominal do sistema de filtragem. Conseqüentemente, enquanto o corte e10 será empregado para as análises dos eventos utilizados neste trabalho, o corte e15i será empregado para as análises destinadas ao desenvolvimento do discriminador elétron / jato, conforme é apresentado no Capítulo 8.

É apresentado, na Tabela 7.2, o número de regiões de interesse obtidas ao final do processo de pré-filtragem pelo L1 para ambos os cortes. O número inicial de

Tabela 7.1: Cortes considerados para o L1 para as duas assinaturas abordadas.

Variável / Corte	e10	e15i
$E_T >$	7 GeV	11 GeV
$Em_{Isol} \leq$	∞	3 GeV
$Had_{Core} \leq$	∞	2 GeV
$Had_{Isol} \leq$	∞	1 GeV

Tabela 7.2: Número de RoI obtidas para cada padrão após filtragem pelo L1, para as assinaturas abordadas (veja a Seção 5.4.1 para detalhes).

Padrão	e10			e15i		
	# Inicial	# após L1	Corte (%)	# Inicial	# após L1	Corte (%)
Elétron	479.902	470.282	2,00	294.040	140.824	52,11
Jato	711.046	314.843	55,72	198.841	13.160	93,38

eventos difere para os dois cortes visto que o corte e10 foi aplicado nas simulações de Monte Carlo produzidas com a versão 14.2.0 do Athena, enquanto que o corte e15i foi aplicado em simulações de Monte Carlo produzidas com a versão 15.0.0³. Como esperado, o corte e15i rejeitou muito mais eventos do que o corte baseado apenas em energia (e10), ao custo de uma maior probabilidade de perda de elétrons. A Figura 7.7 apresenta as distribuições das 4 variáveis de corte empregadas pelo L1 para o conjunto de elétrons e jatos, bem como os limiares de corte de cada variável. O corte por energia transversa, por si só, não é capaz de fazer nenhuma distinção entre elétrons e jatos. A distinção entre os 2 padrões só se torna possível com a aplicação do isolamento. Entretanto, como a Figura 7.7 mostra, a redução do falso alarme, proporcionada pelo isolamento, é acompanhada por um aumento na probabilidade de perda do alvo.

³Embora sejam versões distintas, as propriedades dos eventos são as mesmas, de forma que os resultados apresentados, até este ponto, para as simulações obtidas com a versão 14.2.0 permanecem os mesmos para a versão 15.0.0.

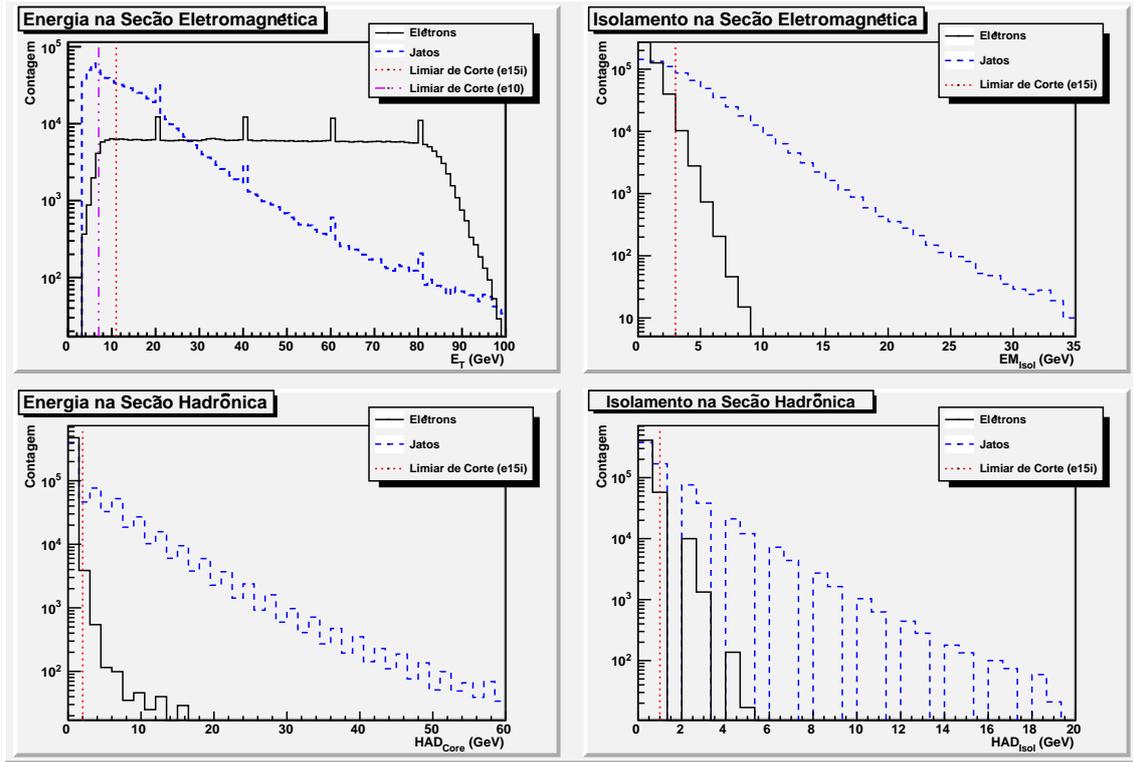


Figura 7.7: Variáveis de corte calculadas pelo L1 para a identificação de elétrons.

7.2 Pré-Processamento por Anéis Topológicos

Os sinais produzidos pelo sistema de calorimetria para uma RoI de tamanho $0,4 \times 0,4$ em $\eta \times \phi$ possuem dimensão elevada e não uniforme (vide Figura 7.8). A variação da dimensão das RoI é reflexo da granularidade de cada camada dos calorímetros do ATLAS. O pré-processamento por anéis topológico [44] (também conhecido como *anelamento*) visa extrair, de maneira compacta, o perfil do chuveiro desenvolvido em cada camada do sistema de calorimetria do ATLAS por um dado evento, garantindo sua interpretação física. Adicionalmente, este pré-processamento deve padronizar a dimensão da informação extraída de cada camada.

O algoritmo de anelamento consiste em, através da localização da célula quente⁴ de cada camada, agrupar as células contidas em uma região de $0,4 \times 0,4$ em $\eta \times \phi$ em anéis concêntricos, construídos ao redor da célula quente. O índice (I_R) do anel ao qual uma célula pertencerá é calculado fazendo-se

⁴Célula que amostra a maior energia.

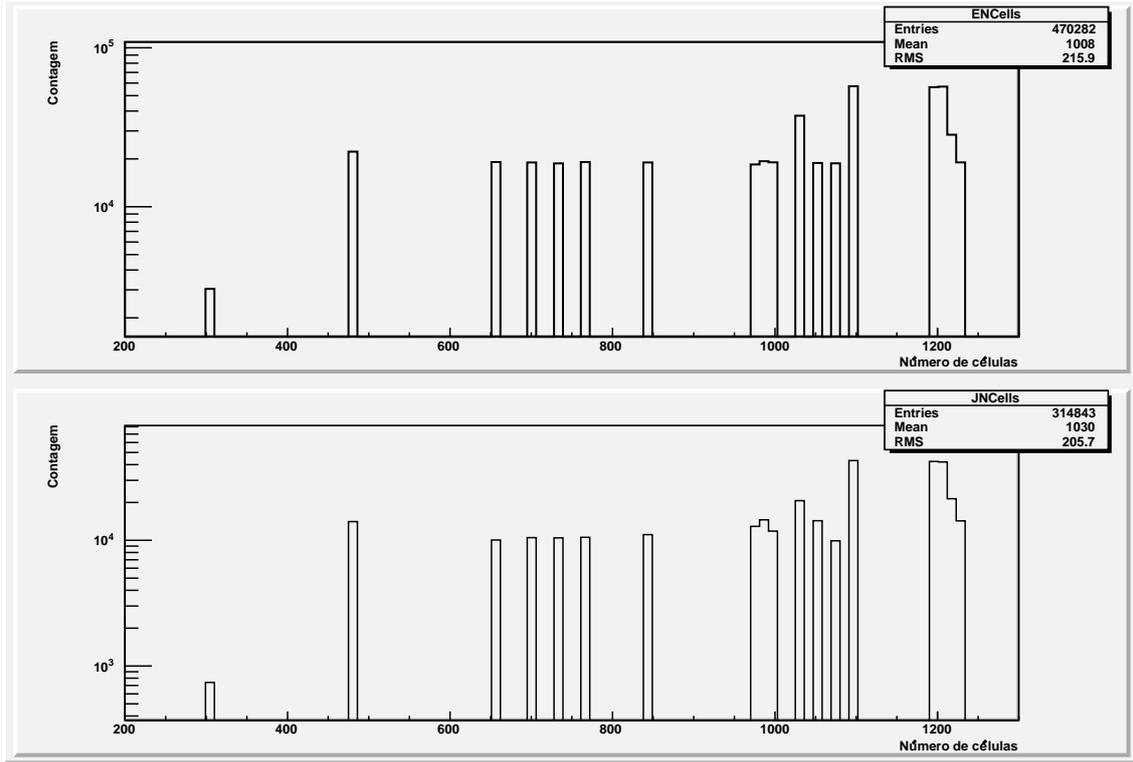


Figura 7.8: Distribuição do número de células de calorimetria por RoI para elétrons (em cima) e jatos (embaixo).

$$I_{\eta} = \text{round} \left(\frac{\eta_c - \eta_0}{\Delta\eta_s} \right) \quad (7.1)$$

$$I_{\phi} = \text{round} \left(\frac{\phi_c - \phi_0}{\Delta\phi_s} \right) \quad (7.2)$$

$$I_R = \max(I_{\eta}, I_{\phi}) \quad (7.3)$$

onde I_{η} é o índice do anel em η , η_c é a posição, em η , da célula sob consideração, η_0 é a posição em η do baricentro da camada da célula, e $\Delta\eta_s$ é o tamanho (resolução), em η , das células pertencentes à camada sendo analisada (a mesma nomenclatura vale para ϕ).

Ao final do processo de anelamento, as energias absorvidas pelas células pertencentes a um dado anel são somadas, produzindo um único valor (soma em anel). Pode-se observar, na Figura 7.9, um exemplo da organização das células em anéis para diferentes camadas dos calorímetros eletromagnético e hadrônico. Nota-se que o anelamento é uma abstração do conceito de deposição concêntrica de energia que leva em consideração a granularidade de cada camada durante a construção dos

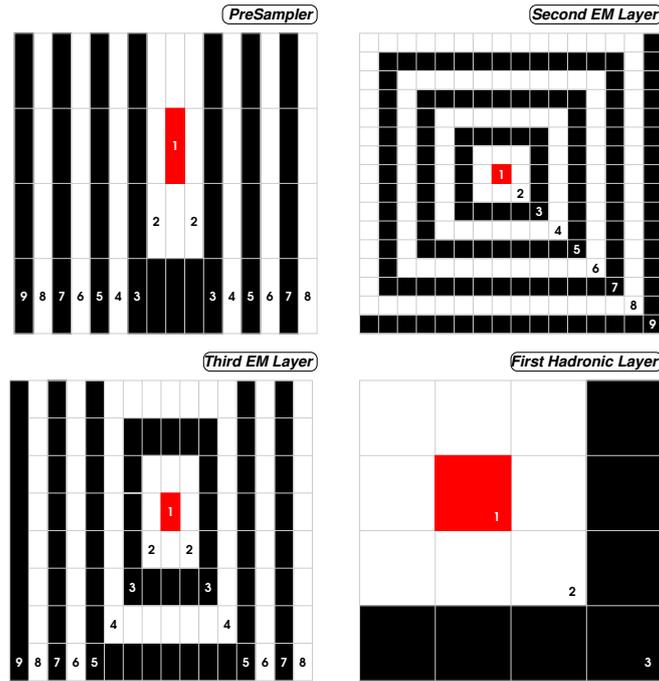


Figura 7.9: Exemplo da organização das células em anéis concêntricos para diferentes camadas dos calorímetros.

anéis. Adicionalmente, o algoritmo de anelamento lida com situações onde, devido a posição do centro da RoI, o anel em construção esteja incompleto (veja como exemplo o 9º anel da 2ª camada EM na Figura 7.9). Por fim, caso um dado anel não contenha nenhuma célula, este receberá o valor zero, para que seja garantida a padronização da dimensão final dos anéis produzidos.

Para cada evento, 7 conjuntos de anéis (um para cada camada do sistema de calorimetria) são gerados, organizados tal como apresentado na Tabela 7.3. Desta maneira, um total de 100 anéis são produzidos para cada evento incidente. A descrição da abreviatura de cada detetor apresentado na Tabela 7.3 pode ser vista na lista de abreviaturas no começo deste trabalho.

7.2.1 Características Gerais

Observam-se, nas Figuras 7.10 e 7.11, as características gerais das RoI após o processo de anelamento, para RoI produzidas pelo corte e10 do L1. Nota-se, para os anéis construídos para elétrons, o perfil de deposição de energia mais concentrado nos primeiros anéis, quando estes são comparados aos jatos. Percebe-se, para os jatos, a maior deposição de energia nas seções hadrônicas, uma vez que o corte e10

Tabela 7.3: Organização dos anéis para cada conjunto.

Camada	Seção	Nº de Anéis	Detetores Utilizados
PS	EM	8	PSBARREL, PSEND CAP
EM1	EM	64	EMBARREL1, EMENDCAP1
EM2	EM	8	EMBARREL2, EMENDCAP2
EM3	EM	8	EMBARREL3, EMENDCAP3
HD1	HAD	4	HADENCAP0, TILEBARREL0, TILEGAPSCI0, TILEEXTB0
HD2	HAD	4	HADENCAP1, TILEBARREL1, TILEGAPSCI1, TILEEXTB1
HD3	HAD	4	HADENCAP2, HADENCAP3, TILEBARREL2, TILEGAPSCI2, TILEEXTB2

não aplica análise de isolamento. Observa-se, também, que nem sempre o primeiro anel é o anel com a maior energia para uma dada camada, haja vista que a soma das células compondo o segundo anel pode ser superior à energia isolada pelo primeiro anel, que é composto por apenas uma única célula.

Observando-se os anéis da última seção hadrônica (HD3) para o conjunto de elétrons, percebe-se um pequeno pico no valor médio destes anéis, e, também, um considerável desvio padrão. Este comportamento advém da forma como os detetores foram distribuídos pelos conjuntos de anéis. Conforme a Tabela 7.3, os conjuntos HD1, HD2 e HD3 incluem, cada um, uma parte (TILEGAPSCI0, TILEGAPSCI1 e TILEGAPSCI2, respectivamente) do cintilador colocado na fenda entre o barril e a tampa do calorímetro eletromagnético. O TILEGAPSCI2 (pertencente à HD3), cobre a região $1 \leq |\eta| \leq 1,6$ (vide Figura 7.13), cobrindo, portanto, a região do *crack*. Como consequência, muita energia é amostrada pelo TILEGAPSCI2, já que este, na região do *crack*, é o primeiro detetor atingido por partículas incidentes, o que culmina no aumento da energia dos anéis da HD3. Este fato fica comprovado ao observar-se a Figura 7.12. Esta figura apresenta, na coluna da esquerda, a energia total concentrada nos anéis que compõem as camadas HD1, HD2 e HD3. Na coluna

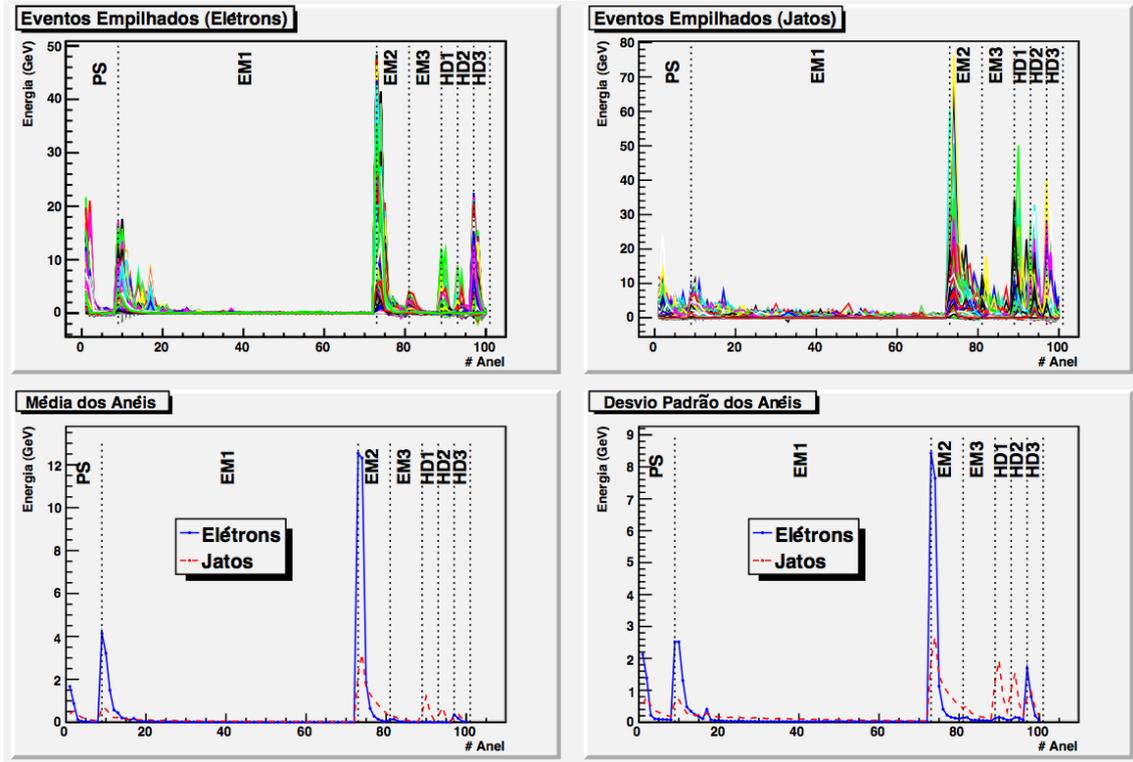


Figura 7.10: Característica geral dos eventos após o anelamento.

da direita, apresenta-se a energia total concentrada em cada uma destas 3 camadas, porém excluindo-se os cintiladores existentes em cada camada. A HD1 e HD2 perderam muito pouca energia com a exclusão de seus cintiladores, diferentemente da HD3, que apresentou uma redução considerável na energia em seus anéis.

Para evidenciar as diferenças produzidas pelos cortes $e10$ e $e15i$, são apresentadas, na Figura 7.14, as características gerais dos anéis produzidos pelas RoI selecionadas pelo corte $e15i$ do L1. Ao compararem-se os eventos obtidos com um corte sem isolamento (Figura 7.10) com os obtidos após a ativação do isolamento no L1 (Figura 7.14), constata-se que, com o isolamento, a distinção entre elétrons e jatos torna-se menos aparente para o L2. Não só os jatos que passam o corte $e15i$ deixam menos energia na seção hadrônica, bem como o perfil lateral do chuva produzido por eles é mais estreito.

7.2.2 Robustez à Extrapolação em ϕ (ϕ *Wrap-Around*)

No processo de anelamento, possíveis casos de extrapolação da coordenada ϕ (vide anexo B) são resolvidos fazendo-se, para cada célula da RoI

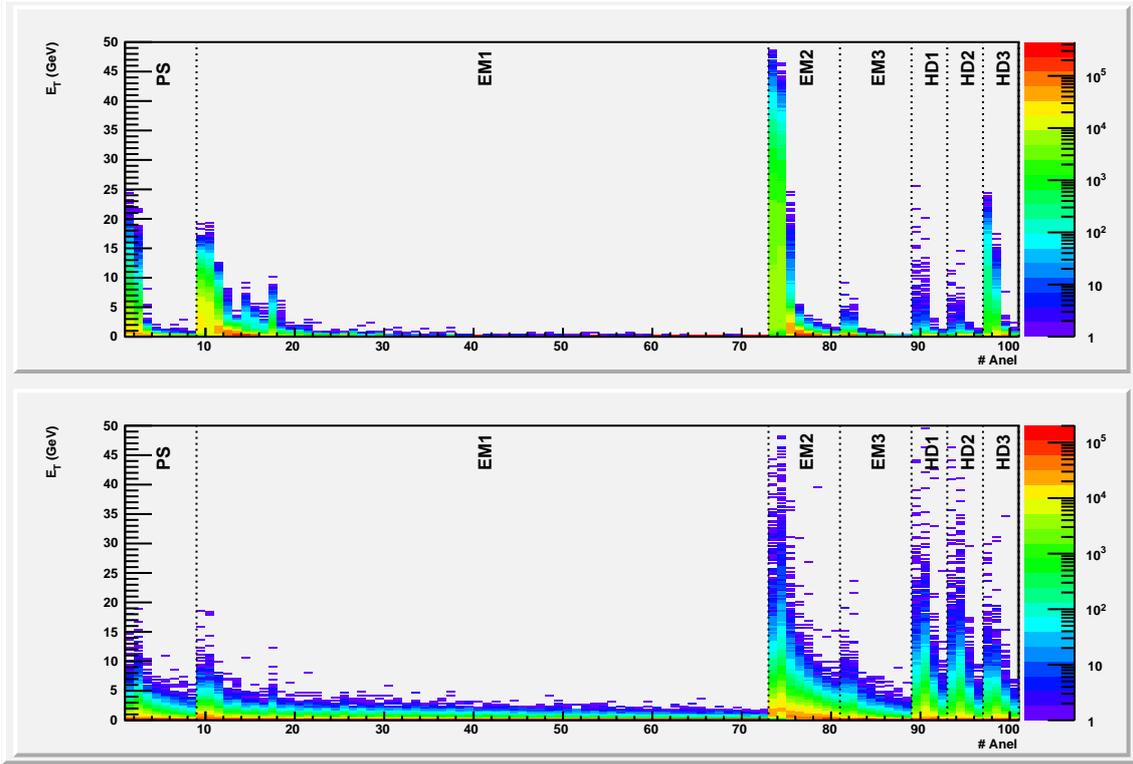


Figura 7.11: Distribuição dos anéis por energia para o corte e10 para elétrons (em cima) e jatos (embaixo).

$$\text{Se } \pi - 1 < \phi_c < \pi \rightarrow \phi_i = \phi_i + 2\pi \quad \forall \phi_i < 0 \quad (7.4)$$

$$\text{Se } -\pi < \phi_c < 1 - \pi \rightarrow \phi_i = \phi_i - 2\pi \quad \forall \phi_i > 0 \quad (7.5)$$

onde ϕ_c é o centro da RoI em ϕ , e ϕ_i é a posição em, ϕ , da i -ésima célula pertencente à RoI em questão. A equação 7.4 é utilizada para casos onde o centro da RoI esteja muito próximo de $+\pi$, enquanto que a equação 7.5 é empregada quando o centro encontra-se próximo de $-\pi$. Com isso, garante-se que o algoritmo de anelamento enxergará a RoI como uma região contínua em ϕ . Na Figura 7.16, são apresentados os histogramas das distribuições de ϕ obtidas para casos de extrapolação em ϕ para $\pm\pi$ (parte superior), e, na parte inferior, os histogramas obtidos após a correção destes casos, usando-se o método descrito pelas equações 7.4 e 7.5.

7.2.3 Correlação Linear entre Anéis

Anéis representam o chuveiro produzido pela interação de partículas com a calorimetria do ATLAS. Sabe-se que o processo de desenvolvimento do chuveiro é um

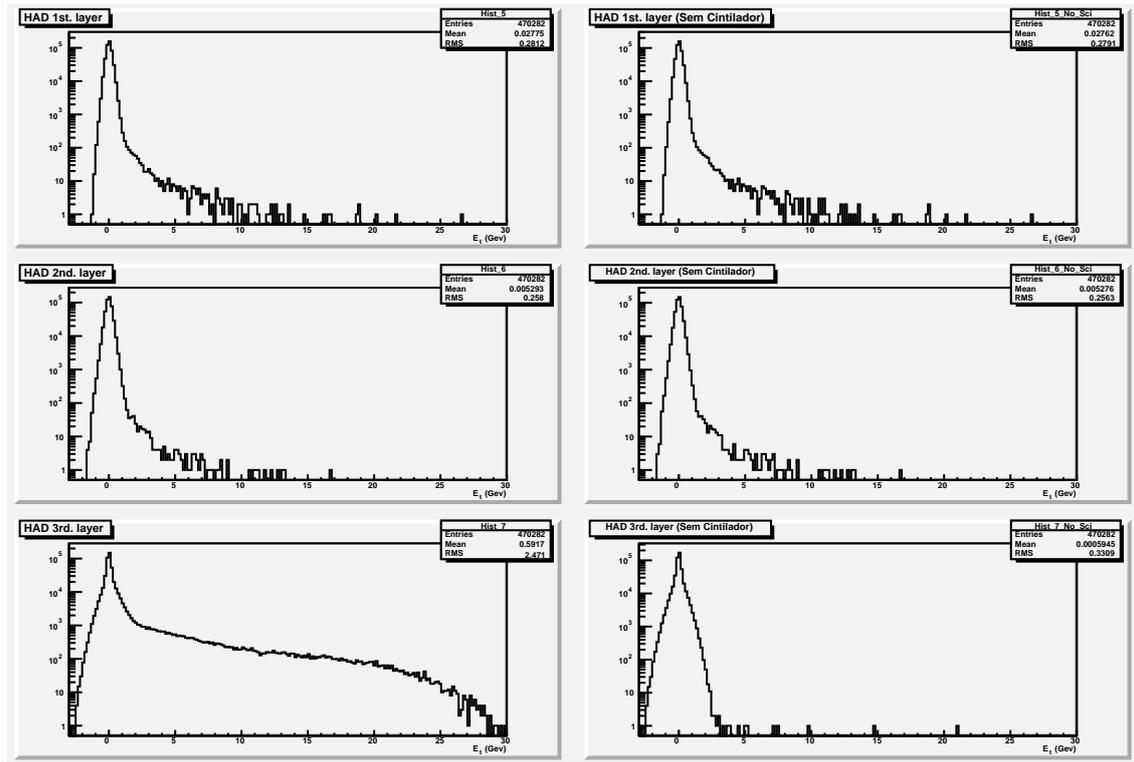


Figura 7.12: Energia depositada em cada grupo de anéis quando ao incluir-se a energia dos cintiladores (coluna da esquerda) e ao excluir-se os cintiladores (coluna da direita).

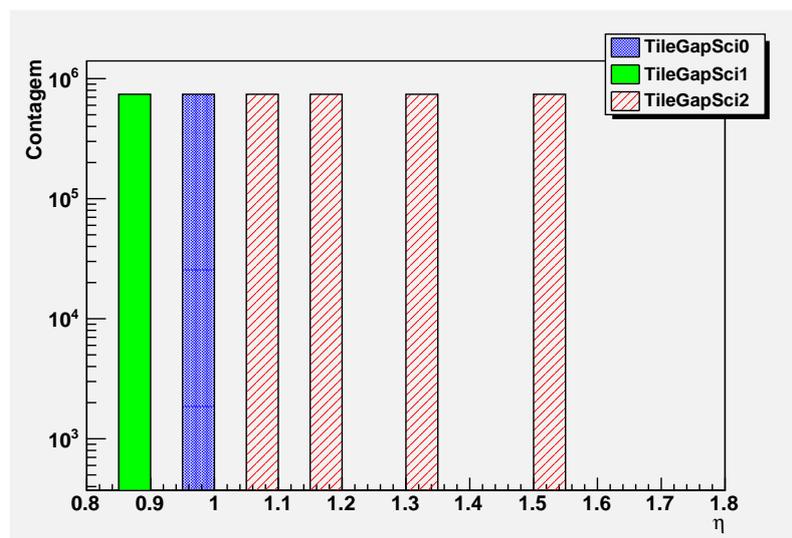


Figura 7.13: Distribuição, em η , das células pertencentes às 3 camadas de cintiladores posicionadas na fenda existente entre o barril e a tampa do calorímetro eletromagnético.

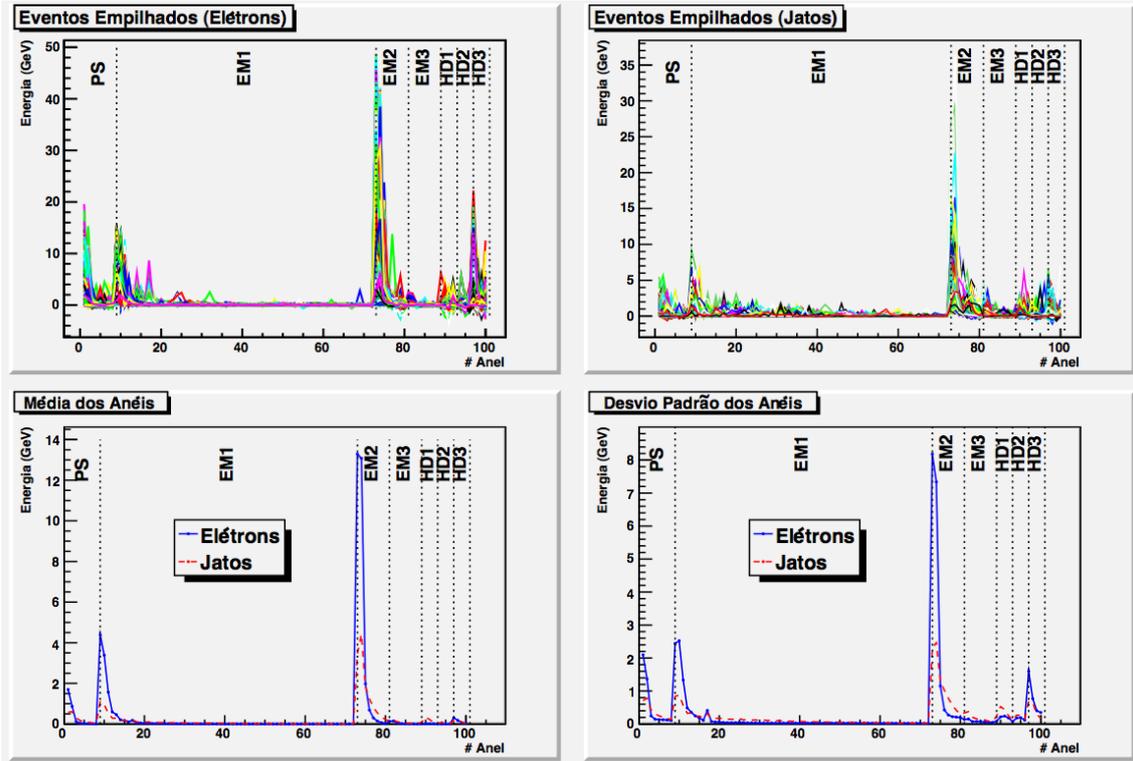


Figura 7.14: Perfil dos anéis após a aplicação do corte com isolamento pelo L1.

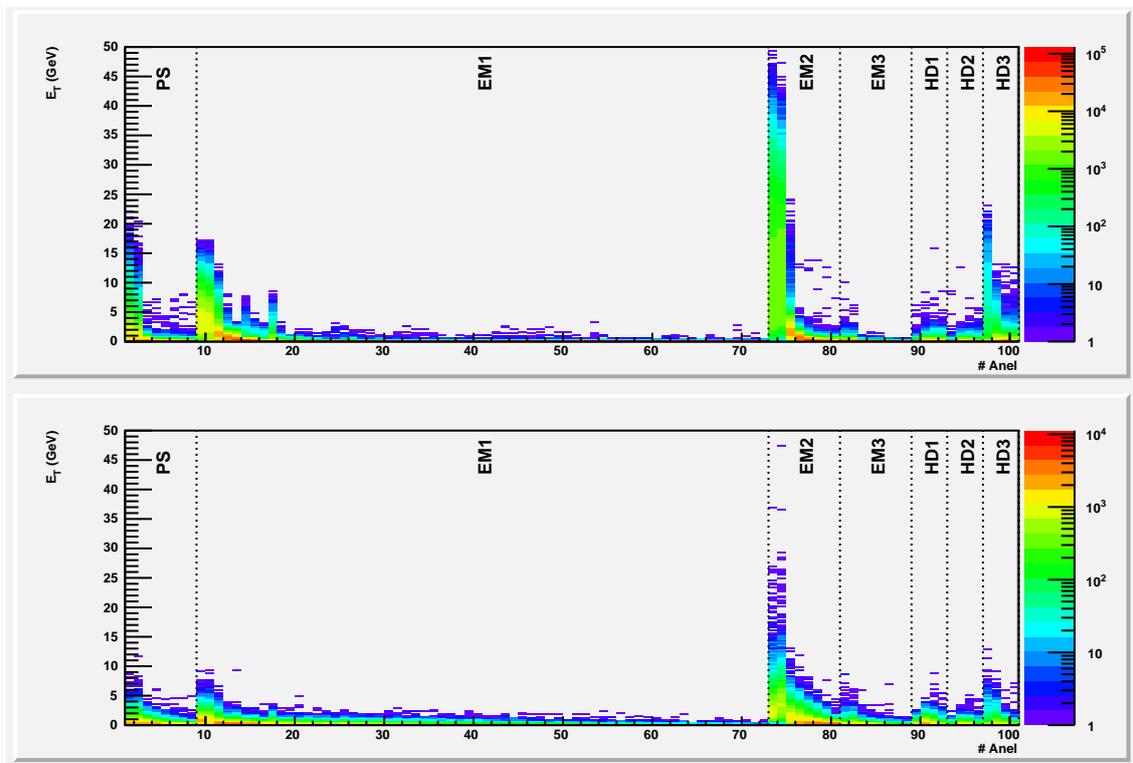


Figura 7.15: Distribuição dos anéis por energia para o corte e15i para elétrons (em cima) e jatos (embaixo).

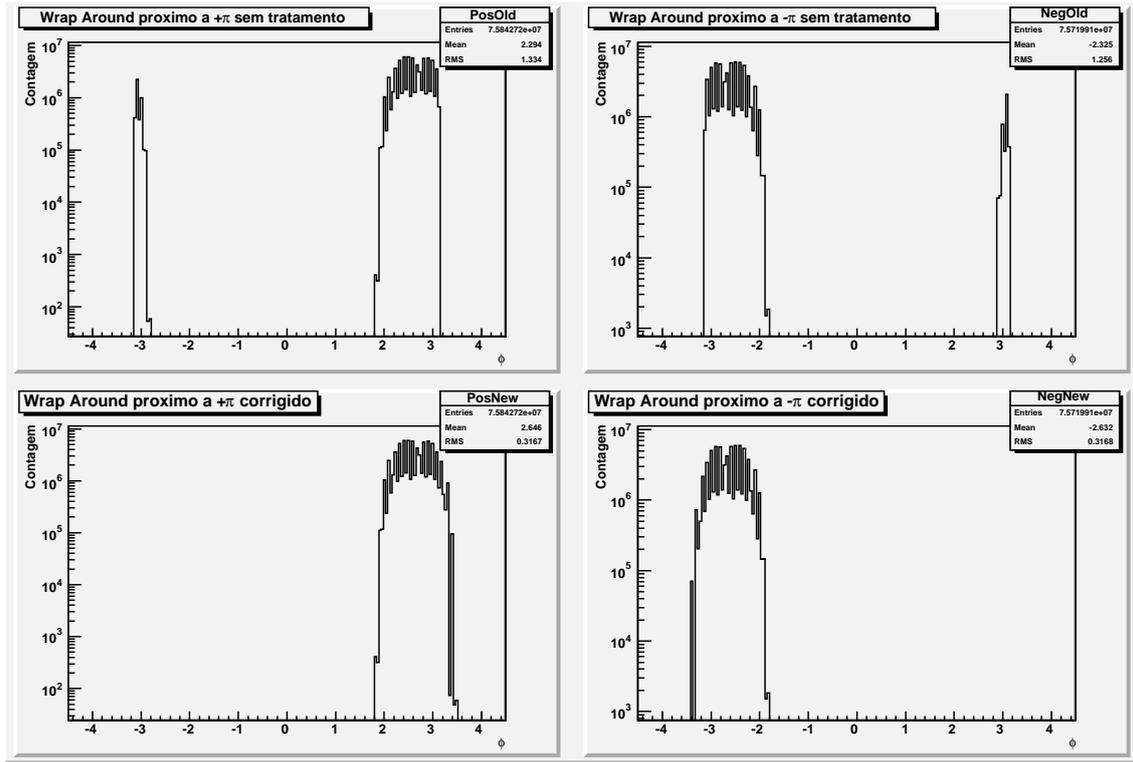


Figura 7.16: Distribuição em ϕ dos casos de ROI com extrapolação da coordenada ϕ na versão original (em cima), e após a correção (embaixo).

processo com muitas correlações. Logo, espera-se que os anéis produzidos reflitam tal correlação. Observa-se, na Figura 7.17, o coeficiente de correlação linear [47] entre os anéis obtidos com os cortes e10 e e15i, para ambas as classes de partículas. A análise geral permite concluir que há correlação entre os anéis de uma mesma camada, o que é esperado dada a física de desenvolvimento dos chuviros no sistema de calorimetria do ATLAS. Observa-se, também, a existência de correlações entre camadas (e até mesmo entre as seções EM e HAD), o que, novamente, é explicado pelo fato de um mesmo chuviro se desenvolver por várias camadas.

Para os elétrons, nota-se grande correlação entre os anéis das camadas eletromagnéticas, e correlação praticamente nula nas camadas hadrônicas (com exceção da HAD3, uma vez que contém o cintilador do *crack*). Este comportamento mostra que toda a informação deste tipo de partícula concentra-se na seção eletromagnética, e que a seção hadrônica é composta por ruído descorrelacionado, o que é condizente com o esperado para este tipo de partícula. Ao analisar-se as diferenças, para elétrons, entre os cortes e10 e e15i, nota-se que, para o corte e15i, a correlação dos anéis mais externos com os demais anéis diminui, uma vez que como resultado da

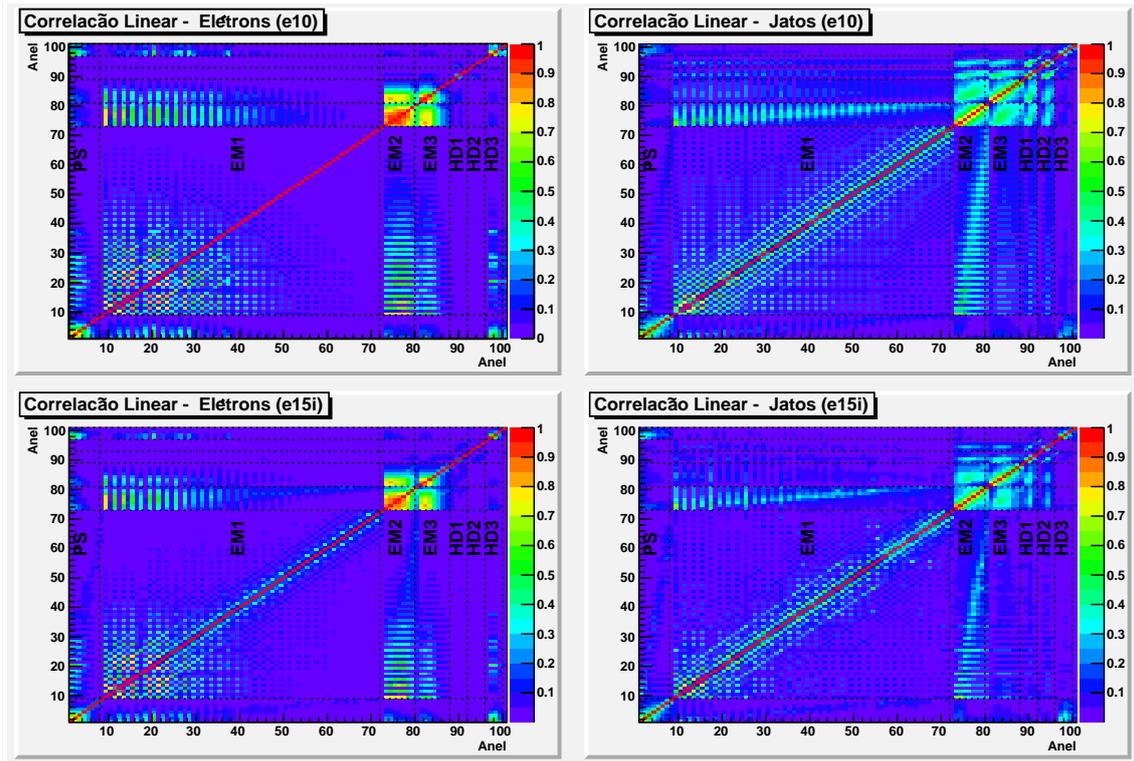


Figura 7.17: Coeficiente de correlação linear entre os 100 anéis para os cortes e10 e e15i.

aplicação do isolamento pelo primeiro nível de filtragem, estes anéis mais externos apresentam relação sinal-ruído mais baixa.

Nos caso dos jatos, para o corte e10, tem-se que a correlação nas camadas eletromagnéticas diminui, ao passo que se observa maior correlação entre os anéis das camadas hadrônicas, o que, novamente, é condizente com o perfil do chuva produzido por partículas hadrônicas nas seções eletromagnéticas e hadrônicas. Tal como os elétrons, a correlação entre os anéis mais externos e os demais também apresenta redução ao aplicar-se o corte com isolamento (e15i) do primeiro nível, o que, novamente, é condizente com as características deste corte.

Para os anéis pertencentes à EM1, observa-se um curioso processo, onde a correlação entre um dado anel e o anel seguinte é muito mais baixa do que o dado anel e o anel duas posições ao lado (exemplo: o anel 10 quase não está correlacionado com o anel 11, mas o anel 10 encontra-se consideravelmente correlacionado com o anel 12). Investigando-se este fenômeno, constatou-se a grande existência de eventos com anéis nulos na EM1, em posições intercaladas (veja um evento de exemplo na parte inferior da Figura 7.18). Estes anéis nulos acabam por influenciar no cálculo

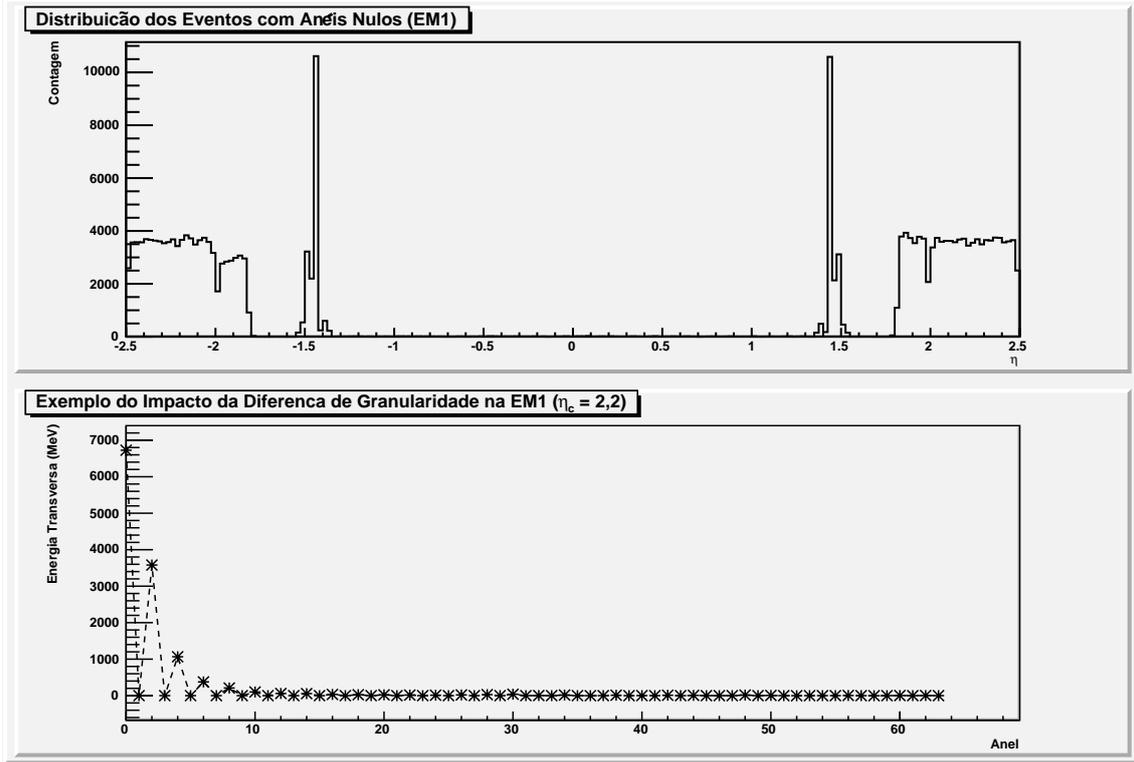


Figura 7.18: Regiões, em η , de ocorrência de anéis nulos na EM1 (em cima), e a distribuição destes anéis nulos para um evento típico (embaixo).

do coeficiente de correlação linear desta camada.

Fazendo-se a distribuição do valor de η de eventos onde pelo menos um dos 10 primeiros anéis é nulo, obteve-se o gráfico apresentado na parte superior da Figura 7.18. Constatou-se, então, que este fenômeno ocorre somente nas regiões, em η , onde a granularidade das células (vide Tabela 3.1) é diferente da granularidade no barril ($|\eta| < 1,4$). No algoritmo de anelamento descrito pelas equações 7.1, 7.2 e 7.3, a dimensão de referência das células ($\Delta\eta_s \times \Delta\phi_s$) é a dimensão das células no barril de cada camada, resultando num processo de intercalação da composição dos anéis. Esta intercalação (k), em η será dado por

$$k = \frac{\Delta\eta_i}{\Delta\eta_s} \quad (7.6)$$

onde $\Delta\eta_i$ é o tamanho, em η , da i -ésima célula sendo analisada para se saber a qual anel pertencerá, e $\Delta\eta_s$ é o tamanho (também em η) padrão (i.e. no barril) a ser considerado pelo algoritmo de anelamento para a s -ésima camada. Na parte inferior da Figura 7.18, apresenta-se, como exemplo desta intercalação, os 64 anéis da EM1,

produzidos para uma RoI típica centrada em $\eta = 2,2$. Nesta região da tampa da EM1 ($2, 0 \leq |\eta| < 2,4$), cada célula tem dimensão, em η , igual ao dobro (0,00625) da dimensão daquelas encontradas no barril desta camada (0,003125), de tal modo que $k = 2$ na equação 7.6. Assim, para esta RoI, os anéis estarão intercalados de 2 posições, conforme pode ser observado no gráfico da parte inferior da Figura 7.18.

Para os eventos centrados, em η , na região $1,375 \leq |\eta| < 1,5$, a dimensão das células, na EM1, é $\Delta\eta = 0,025$, o que resulta em $k = 8$, o que explica por que o 9º anel da EM1 apresenta correlações mais fortes apenas com o 1º, 17º, 25º, ... anéis da EM1.

7.2.4 Correlação Não Linear

Embora a correlação linear possa fornecer informações úteis a respeito do conjunto de anéis, esta análise não é capaz de observar características não lineares compartilhadas pelos anéis, uma vez que a correlação linear só utiliza momentos de primeira e segunda ordem.

Uma análise mais poderosa, que permite observar a dependência estatística entre os anéis é a informação mútua [79]. A informação mútua, entre duas variáveis u e v , é dada por

$$I(u, v) = H(u) + H(v) - H(u, v) \quad (7.7)$$

onde $H(\cdot)$ é a função de entropia [79].

A informação mútua, diferentemente do coeficiente de correlação linear, só é limitada em seu limite inferior, dificultando a análise de dependência entre os anéis. Para resolver este problema, em [80] foi proposto o uso de

$$\rho_{uv}^2 = 1 - e^{-2I(u,v)} \quad (7.8)$$

para limitar o valor da informação mútua na região $[0, 1]$. É apresentada, na Figura 7.19, a matriz com a informação mútua entre os anéis de elétrons e jatos, obtidos com os cortes com e sem isolamento do primeiro nível de filtragem. Para os 4 gráficos, a informação mútua foi normalizada pela equação 7.8. A análise desta figura permite concluir que existe não só dependência estatística entre os anéis, mas, também, dependência entre as camadas, mesmo que pertencentes a seções distintas.

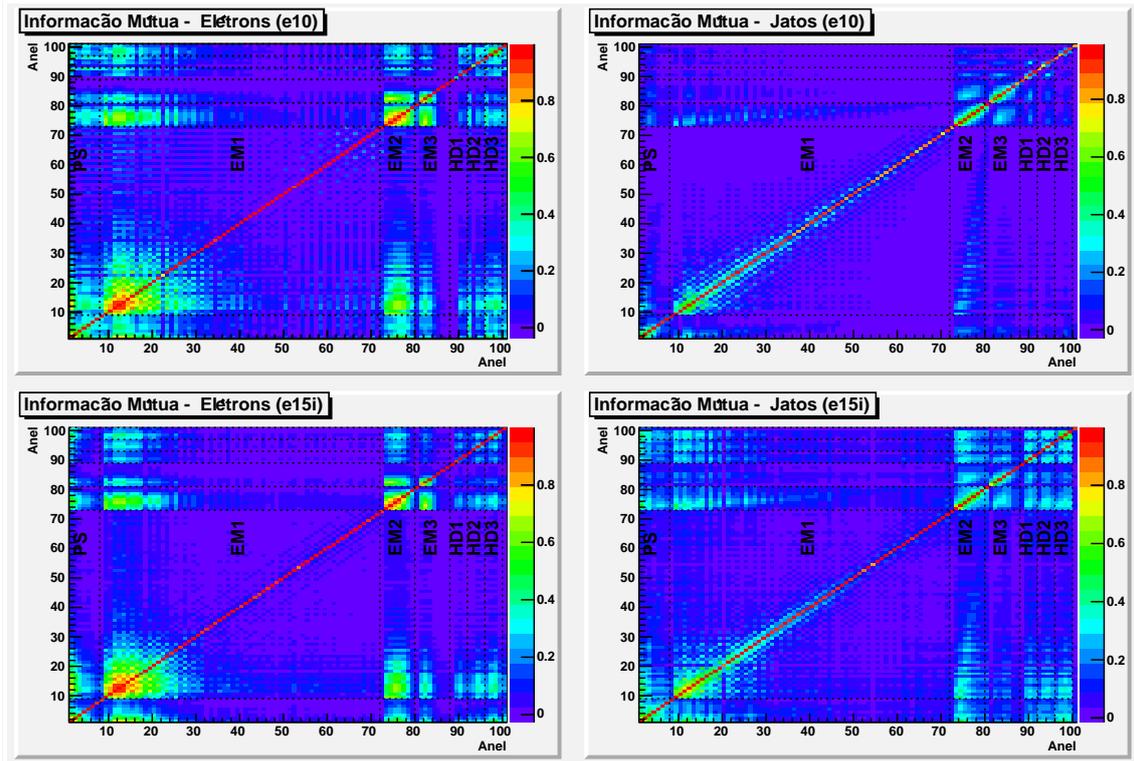


Figura 7.19: Informação mútua (normalizada) entre os 100 anéis para os cortes e10 e e15i.

No caso dos elétrons, a informação mútua identificou dependências mais fortes entre os anéis (mesmo que de camadas ou seções diferentes), quando comparada ao conjunto de jatos. Novamente, isto se explica pelo comportamento mais imprevisível apresentado por chuveiros hadrônicos. Observa-se, finalmente, que a dependência entre os anéis, tal como na correlação linear, também sofre redução ao ativar-se o isolamento do primeiro nível.

7.2.5 Normalização dos Anéis

No projeto do sistema de classificação elétron / jato, é indispensável tornar o sistema o mais insensível possível a variações de energia dos eventos, priorizando-se a análise do formato do chuveiro de partículas criado durante a incidência de um elétron ou jato. Com isso, espera-se uma generalização da solução para um largo espectro de energia.

Em [44], foi proposto um algoritmo de normalização que, não só torna o sistema mais insensível à variação de energia dos sinais de entrada, como realça a

informação contida nos anéis mais externos, visto que estes representam o perfil lateral do chuveiro produzido. Entretanto, outras abordagens baseadas na energia do evento podem ser adotadas. A normalização de cada anel pela energia total contida no evento de entrada permite que as proporções de energia depositada em cada camada sejam respeitadas. Por outro lado, uma normalização baseada na informação de cada camada permitiria realçar informações de camadas que retêm pouca energia, mas são relevantes para a classificação. Entretanto, a normalização por energia da camada pode amplificar o sinal de camadas compostas apenas por ruído, prejudicando a análise do algoritmo classificador. Uma abordagem mais equilibrada pode ser normalizar os anéis pela energia da seção a que pertencem, o que reduziria o problema mencionado para a normalização por camada. A seguir, algumas destas técnicas de normalização por energia serão apresentadas.

Para determinar-se a melhor normalização por energia, a ser aplicada aos anéis produzidos, as seguintes estratégias de normalização foram exploradas:

Energia Total

Neste modo de normalização, cada um dos anéis (r) produzidos é normalizado pela energia total (considerando-se todas as camadas) contida em uma região de $0,4 \times 0,4$ em $\eta \times \phi$ do evento fazendo-se

$$r'_i = \frac{r_i}{\sum_{j=1}^N r_j} \quad \forall \quad i = 1, 2, 3, \dots, N \quad (7.9)$$

onde N é o número de anéis produzidos, considerando todas as camadas (i.e. 100). O objetivo desta normalização é reduzir a influência da energia de cada evento nas análises, mantendo, ainda assim, a proporção de energia contida em cada anel.

Energia da Camada

Neste modo de normalização, os anéis (r_c) produzidos na c -ésima camada (PS, EM1, HD1, etc.) são normalizados pela energia contida na camada, em uma região de

$0,4 \times 0,4$ em $\eta \times \phi$, fazendo-se

$$r'_{c_i} = \frac{r_{c_i}}{\sum_{j=1}^{N_c} r_{c_j}} \quad \forall \quad i = 1, 2, 3, \dots, N_c \quad (7.10)$$

onde N_c é o número de anéis produzidos na c-ésima camada. Neste modo de normalização, objetiva-se equiparar, do ponto de vista energético, a informação contida em cada camada.

Energia da Seção

Neste modo de normalização, os anéis (r_s) produzidos na s-ésima seção (eletromagnética ou hadrônica) são normalizados pela energia contida na seção, em uma região de $0,4 \times 0,4$ em $\eta \times \phi$, fazendo-se

$$r'_{s_i} = \frac{r_{s_i}}{\sum_{j=1}^{N_s} r_{s_j}} \quad \forall \quad i = 1, 2, 3, \dots, N_s \quad (7.11)$$

onde N_s é o número de anéis produzidos na s-ésima seção. Neste modo de normalização, objetiva-se equiparar, do ponto de vista energético, a informação contida em cada seção.

Sequencial

Esta técnica de normalização visa amplificar as diferenças no perfil lateral dos chuvis produzidos. Nesta técnica, os anéis (r_c) produzidos na c-ésima camada são normalizados fazendo-se

$$r'_{c_i} = \frac{r_{c_i}}{E_{tot_c} - \sum_{j=1}^{i-1} r_{c_j}} \quad (7.12)$$

onde E_{tot_c} é a energia total da c-ésima camada. Esta normalização pode ser interpretada como uma otimização da normalização por energia da camada, amplificando a contribuição dos anéis mais externos ao centro da RoI, através da aplicação de fatores de normalização sucessivamente menores. Para evitar a amplificação de anéis contendo apenas ruído, quando o fator de normalização fica menor do que um dado limiar ($E_{stop} = 100$ MeV), todos os anéis restantes passam a ser normalizados pela

energia total da camada (E_{tot_c}). Adicionalmente, para evitar que camadas contendo apenas ruído sejam normalizadas, caso E_{tot_c} fique abaixo de um dado limiar ($E_{thres} = 0,01$ MeV), nenhuma normalização é aplicada para a camada em questão.

Norma 2

Cada anel foi normalizado por

$$r'_i = \frac{r_i}{\|\mathbf{r}\|} \quad \forall \quad i = 1, 2, 3, \dots, N \quad (7.13)$$

onde $\|\mathbf{r}\|$ é a norma 2 dos N anéis produzidos.

Energia Transversa

Cada anel foi normalizado por

$$r'_i = \frac{r_i}{E_T} \quad \forall \quad i = 1, 2, 3, \dots, N \quad (7.14)$$

onde E_T é a energia transversa da RoI.

Esferização dos Anéis

Cada anel foi normalizado por

$$r'_i = \frac{r_i - \bar{r}_i}{\sigma_{r_i}} \quad \forall \quad i = 1, 2, 3, \dots, N \quad (7.15)$$

onde \bar{r}_i e σ_{r_i} são, respectivamente, a média e o desvio padrão do i -ésimo anel.

Para cada estratégia de normalização por energia, uma rede neural foi treinada, com topologia e parâmetros de treinamento iguais aos descritos na Seção 7.3. A análise da eficiência de classificação foi feita empregando-se a curva ROC [81] e o falso alarme obtido para uma dada probabilidade de detecção. Entretanto, em sistemas de filtragem para experimentos com colisionadores, é comum o falso alarme ser apresentado como taxa, e não como probabilidade. A taxa de falso alarme (R), medida em *Hertz*, é definida como [82]

$$R = P_{fa} \times L \times \sigma \quad (7.16)$$

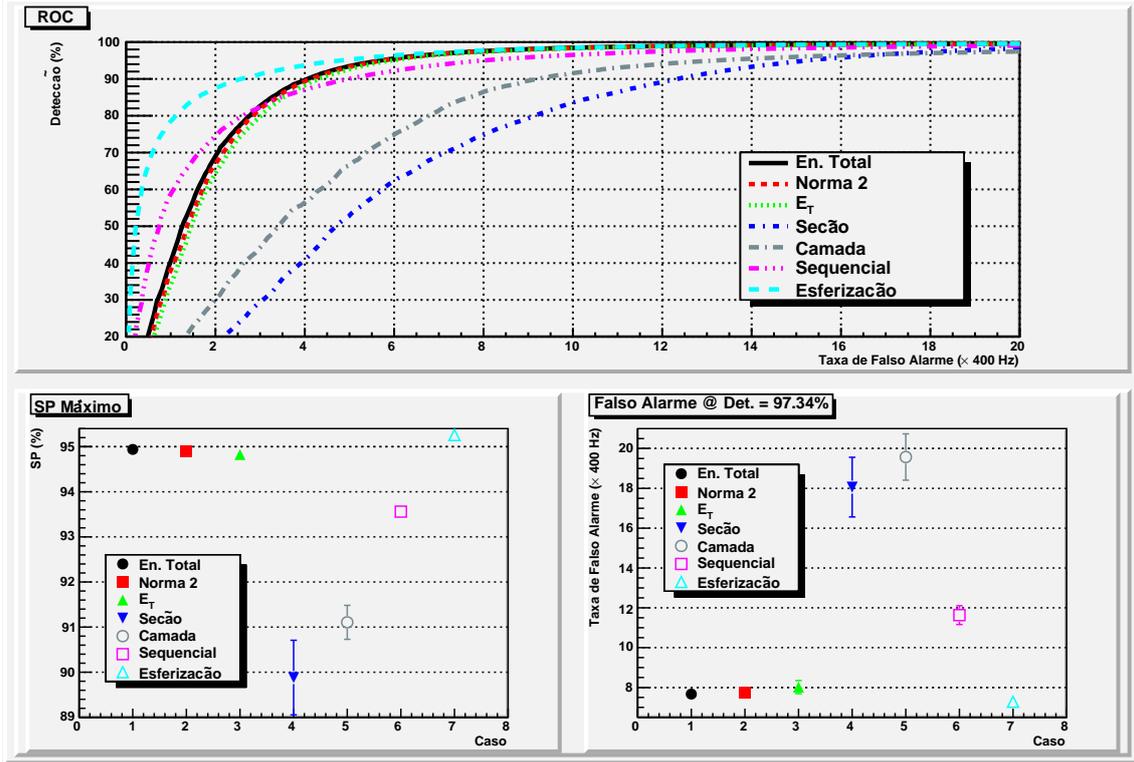


Figura 7.20: Eficiência de classificação para os diversos tipos de normalização em energia considerado para os anéis.

onde P_{fa} é a probabilidade de falso alarme, L é a luminosidade da colisão ($2 \times 10^{33} \text{ cm}^{-2}\text{s}^{-1}$ para os conjuntos empregados), e σ é a seção transversal do evento de interesse ($20 \times 10^{-30} \text{ cm}^2$ para os jatos) [82].

É apresentado, na Figura 7.20, a eficiência de classificação obtida após o treinamento de um classificador neural alimentado pelos anéis normalizados por cada caso. As normalizações por energia total, norma 2 e energia transversa apresentaram resultados similares, visto que as 3 técnicas utilizam a informação de todo o evento para determinar o fator de normalização a ser empregado em cada anel. As três técnicas obtiveram um dos melhores resultados, entre as 8 técnicas estudadas. A normalização por energia da seção e da camada obtiveram um resultado bastante inferior às demais normalizações. Entretanto, ao aplicar-se a normalização sequencial em cada camada, o resultado melhora consideravelmente, mas, ainda assim, fica pior que os resultados obtidos para a normalização por energia total. Por fim, a normalização por esferização apresentou resultados muito melhores que as demais normalizações para baixos valores de falso alarme. Entretanto, conforme a eficiência de detecção aumenta, os resultados com esta normalização se equiparam com os

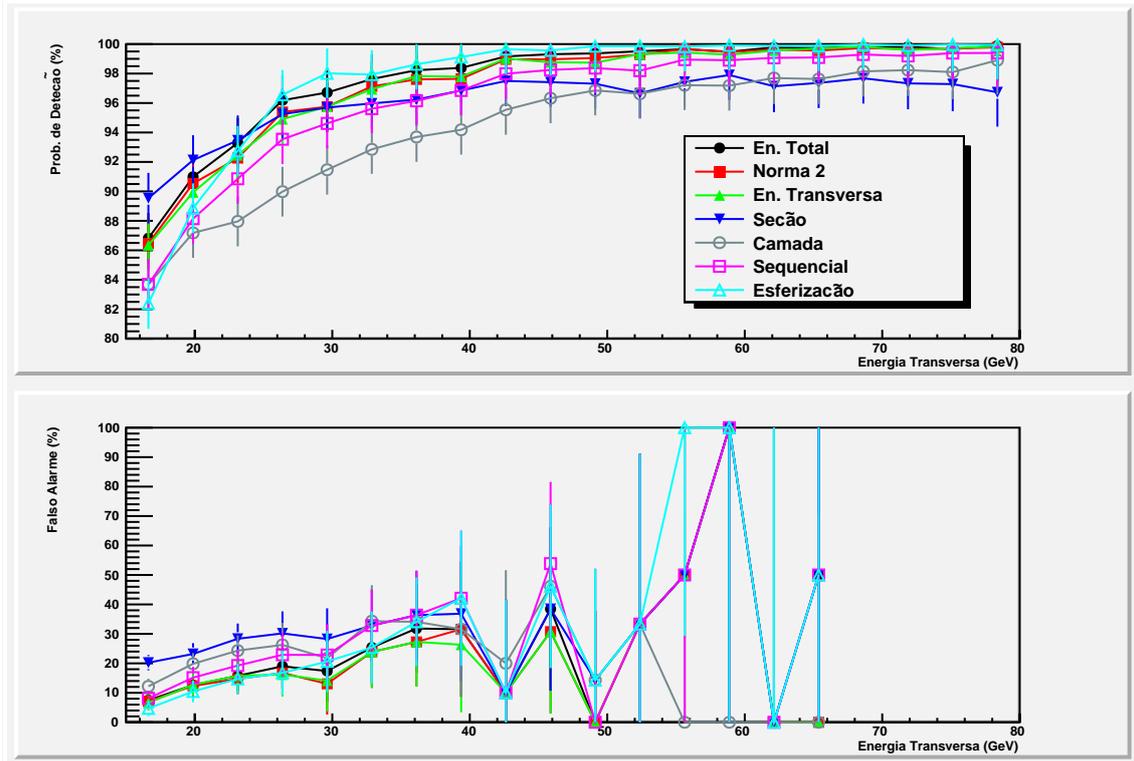


Figura 7.21: Variação da probabilidade de detecção (em cima) e do falso alarme (embaixo) em função da energia transversa do evento.

obtidos para a normalização baseada na energia total do evento.

Uma vez que o objetivo desta normalização dos anéis topológicos é reduzir a sensibilidade do projeto a variações de energia do evento de entrada, torna-se importante analisar a eficiência de cada uma das normalizações propostas, em função da energia do evento. A variação da probabilidade de detecção e do falso alarme em função da energia transversa pode ser visualizada na Figura 7.21⁵. Nota-se que, em baixas energias, a normalização pela energia da seção apresenta melhores eficiências de detecção, produzindo, entretanto, um dos piores resultados para altas energias (> 30 GeV). Adicionalmente, o falso alarme é consideravelmente mais alto para esta normalização, ao longo de toda a faixa dinâmica da energia. A normalização por energia da camada também não apresentou, comparativamente, bons resultados, ficando praticamente, durante toda a faixa dinâmica, com a pior probabilidade de detecção, e ficando com um falso alarme melhor apenas do que a normalização por energia da seção. Já as normalizações por energia total, norma 2 e energia transversa,

⁵O erro de cada medida foi aproximado por $1/\sqrt{N}$, onde N é o número de eventos em cada ponto.

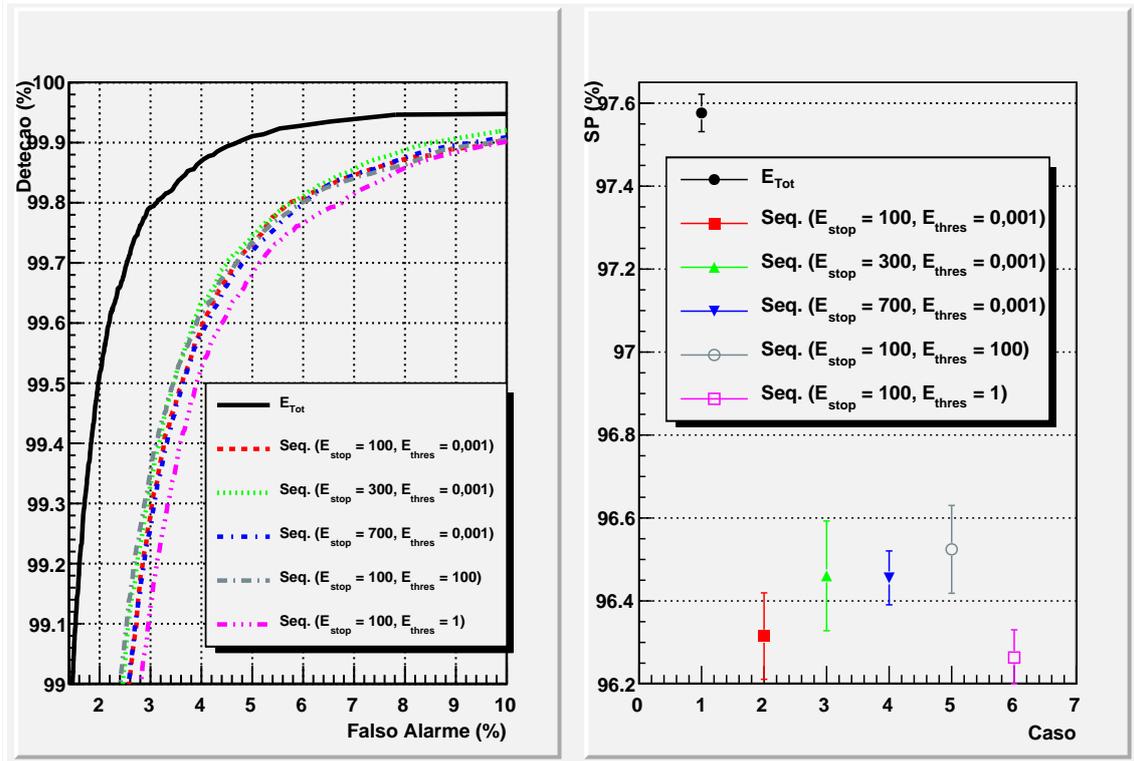


Figura 7.22: Eficiências obtidas com a normalização sequencial, ao variar-se seus limiares E_{stop} e E_{thres} .

apresentaram resultados tecnicamente empatados. Estas três normalizações foram capazes de produzir resultados, comparativamente às outras técnicas, bastante satisfatórios, obtendo uma alta eficiência de detecção aliada à uma baixa incidência de falso alarme. Por fim, a normalização por esferização apresentou resultados muito discretamente superiores aos obtidos com a normalização por energia total.

De acordo com o conhecimento especialista sobre a forma como os anéis representam o chuveiro produzido, era de se esperar que a normalização sequencial produzisse os melhores resultados, uma vez que contribui para evidenciar diferenças entre o perfil lateral do chuveiro produzido por elétrons e jatos. Embora esta normalização tenha produzido um significativo ganho, em relação à normalização por camada, ela não foi capaz de superar todos os outros processos de normalização empregados. Em [44], esta normalização provou ser a melhor opção para o conjunto de dados empregados naquele trabalho. Neste trabalho, acredita-se que a normalização sequencial não tenha produzido resultados superiores às outras abordagens dados os valores adotados para E_{stop} e E_{thres} . O ajuste fino destes limiares se faz necessário para determinar o ponto ótimo onde a normalização sequencial deve ser interrom-

vida, e os casos onde a mesma não deve sequer ser executada. Como exemplo, a Figura 7.22 apresenta, para uma rede neural treinada com dados filtrados pelo corte e_{10} , as eficiências de classificação obtidas ao alterar-se os 2 limiares empregados pela normalização sequencial. Como referência, também é apresentado o resultado obtido para estes dados, ao normalizar-se os eventos pela energia total dos mesmos. Os resultados mostram que maiores ganhos com a normalização sequencial podem ser obtidos através do ajuste fino de E_{stop} e E_{thres} , indicando que futuros trabalhos devem ser conduzidos para esta normalização.

Os resultados apresentados nas Figuras 7.20 e 7.21 mostram que a normalização por esferização e a normalização por energia total foram as que apresentaram os melhores resultados. Entretanto, a normalização por energia total, além de apresentar resultados muito próximos aos obtidos com esferização, é fisicamente mais fácil de interpretar. Desta forma, a normalização por energia total será a escolhida para ser aplicada aos anéis produzidos.

7.2.6 Influência do Cintilador

O algoritmo de anelamento, tal como proposto em [44], inclui a informação de energia amostrada pelos cintiladores na composição dos anéis. Na Seção 7.2.1, observou-se o impacto desta inclusão no resultado final do algoritmo de anelamento. A inclusão do cintilador na composição dos anéis da seção hadrônica resulta em um aumento de energia nestes anéis, o que pode prejudicar a distinção entre elétrons e jatos, visto que esta energia na seção hadrônica aumenta não por causa da produção de um chuveiro no calorímetro hadrônico (característico de jatos), podendo, potencialmente, confundir um sistema de discriminação.

Para se determinar o impacto da inclusão dos cintiladores na composição dos anéis na eficiência de classificação, dois classificadores neurais (com parâmetros tal como serão apresentados na Seção 7.3) foram treinados. Um classificador foi alimentado com anéis contendo a informação dos cintiladores, e o outro foi treinado com anéis sem a inclusão desta informação.

É apresentado, na Figura 7.23, a eficiência de classificação obtida para o discriminador desenvolvido para cada conjunto de dados. Observa-se que, embora a informação do cintilador possa incrementar a energia contida nos anéis hadrônicos,

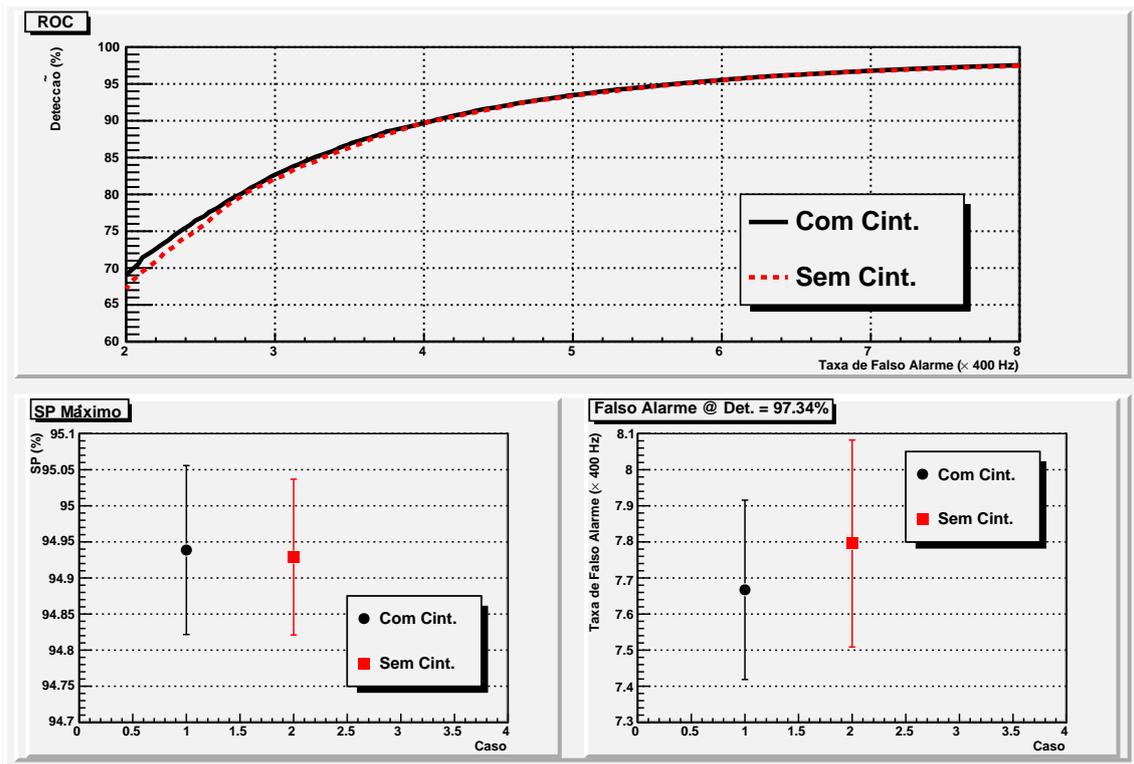


Figura 7.23: Eficiência obtida com discriminadores neurais treinados com anéis produzidos com e sem a informação dos cintiladores.

a rede neural fica insensível a esta mudança, visto que ambos os classificadores obtiveram resultados equivalentes.

A Figura 7.24 apresenta a distribuição bidimensional comparando a saída obtida para ambos os classificadores. As linhas contínuas indicam o limiar de corte que proporciona o melhor produto SP para cada caso. Estas linhas dividem as Figuras 7.24a e 7.24b em 4 quadrantes que definem as regiões de erro e acerto de cada classificador. Por exemplo, os pontos contidos no quadrante superior esquerdo da Figura 7.24a representam os eventos que foram corretamente classificados como elétrons pela rede treinada sem a informação dos cintiladores, e os eventos que foram erroneamente classificados como jatos pela rede treinada com a inclusão dos cintiladores. O quadrante superior direito, por outro lado, contém os eventos que foram corretamente identificados por ambos os classificadores. No caso dos jatos, na Figura 7.24b, a lógica fica invertida. Por exemplo, o quadrante superior direito contém os jatos que foram erroneamente classificados como elétrons por ambas as classes.

Para comparar o desacordo entre os dois classificadores, deve-se observar os even-

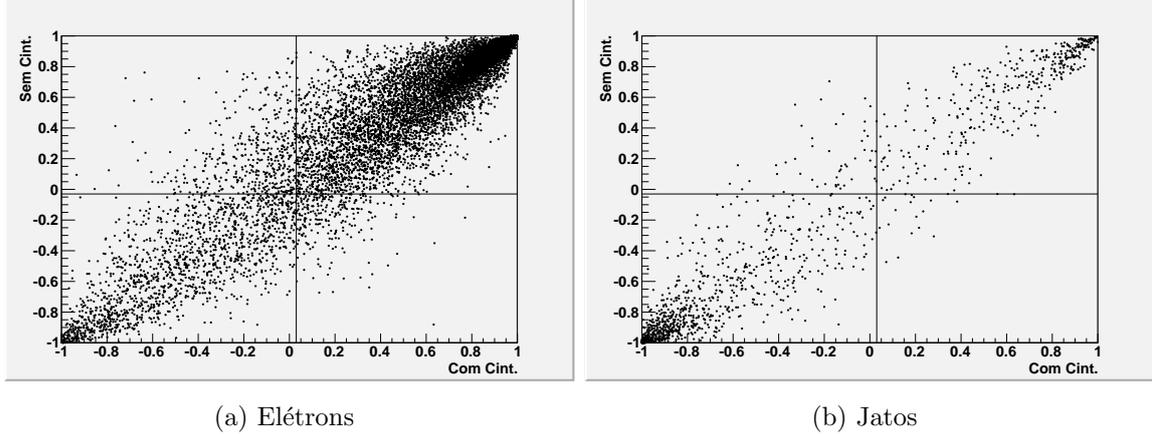


Figura 7.24: Distribuição bidimensional das saídas das redes neurais treinadas para anéis com e sem a informação dos cintiladores.

tos contidos no quadrante superior esquerdo, e no quadrante inferior direito de cada figura (regiões de desacordo entre os classificadores). Nota-se que o classificador treinado sem a informação dos cintiladores foi um pouco mais eficiente que o discriminador alimentado sem esta informação. Na Figura 7.25, apresenta-se a distribuição em E_T e η dos eventos contidos nos quadrantes correspondentes ao desacordo entre os dois classificadores. O eixo das ordenadas contém o percentual de eventos em uma dada região de E_T ou η . No caso da energia transversa do conjunto de elétrons, por exemplo, a linha mais escura (com marcador no formato de círculo), representam, para uma dada energia, a quantidade (em valores percentuais) de eventos contidos no quadrante superior esquerdo da Figura 7.24a.

Analisando-se a Figura 7.25, observa-se, para o conjunto de elétrons, que a rede treinada sem a informação dos cintiladores obteve, na média, melhores resultados na região $E_T < 20$ GeV. Entretanto, esta diferença está dentro da flutuação estatística do processo, de tal forma que não pode ser considerada significativa. O mesmo ocorre, para elétrons, quando se observa o desacordo entre os classificadores em função de η . Novamente, os resultados da rede treinada sem os cintiladores ficaram ligeiramente acima da outra abordagem, porém ainda contidos na zona representante da flutuação estatística do processo. Para o conjunto de jatos, tanto em E_T , como em η , também não são observadas diferenças marcantes entre as abordagens, visto que todos os valores encontram-se dentro do desvio padrão do processo.

As análises realizadas comparando-se as eficiências de classificação obtidas para

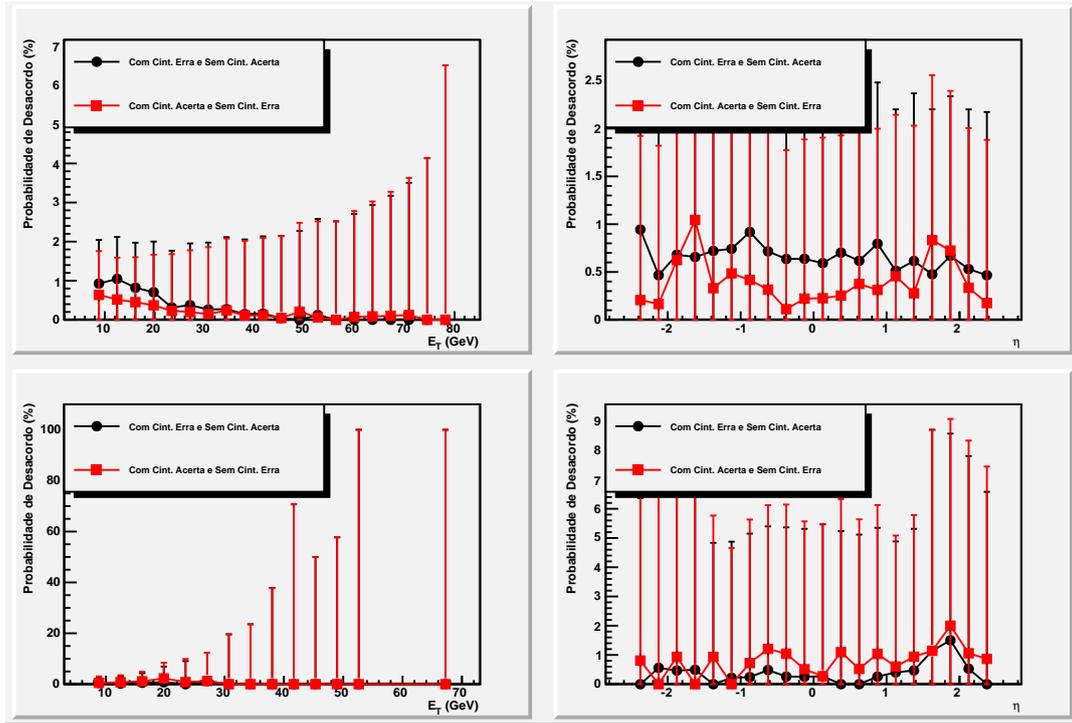


Figura 7.25: Probabilidade de desacordo, em função de E_T (à esquerda) e η (à direita), para o conjunto de elétrons (em cima) e jatos (embaixo), dos classificadores alimentados com anéis com e sem a informação dos cintiladores.

um discriminador neural treinado com anéis contendo a informação dos cintiladores, e para um discriminador treinado com anéis contendo a informação destes detetores, mostra que as diferenças entre as abordagens podem ser negligenciadas. Desta forma, este trabalho prosseguirá empregando anéis produzidos levando-se em consideração a informação amostrada pelos cintiladores.

7.3 Classificadores Neurais

Na etapa de classificação do sistema de discriminação elétron / jato sendo desenvolvido, redes neurais artificiais [83] serão empregadas. Desta forma, torna-se necessário especificar a melhor topologia e os parâmetros adequados para o treinamento do classificador.

7.3.1 Especificação da Topologia

No que tange a topologia da rede neural, decidiu-se por utilizar uma rede *multi-layer perceptron* totalmente conectada, contendo uma única camada escondida. Em [44], bons resultados de discriminação foram obtidos com 10 neurônios na camada escondida. Desta forma, decidiu-se, neste trabalho, empregar a mesma quantidade de neurônios para esta camada, e função de ativação tangente hiperbólica. A camada de saída conterá apenas um único neurônio, também com função de ativação tangente hiperbólica, e será treinada para fornecer valor de saída +1 para elétrons, e -1 para jatos.

7.3.2 Especificação do Treinamento

Os conjuntos de elétrons e jatos serão divididos de tal forma que 50% dos eventos de cada classe serão empregados para o desenvolvimento das técnicas de pré-processamento e treinamento dos classificadores. Os outros 50% serão empregados para a análise do critério de parada das redes neurais empregadas (validação) e para o teste de comparação entre diferentes abordagens.

Para a inicialização dos pesos, será utilizado o algoritmo *Nguyen-Widrow* [84]. O treinamento utilizado, por sua vez, será o *Resilient Backpropagation* [85]. Ao final do treinamento, a rede neural conterá os pesos sinápticos que proporcionaram o melhor resultado para a figura de mérito de treinamento adotada, de acordo com o critério *Save the Best*.

Para o treinamento dos classificadores neurais, um estudo foi conduzido para determinar:

- A figura de mérito para o treinamento.
- O número de épocas de treinamento.
- O tamanho da batelada.
- O critério de parada.

Para o critério de validação, testou-se o erro médio quadrático (MSE) e o produto

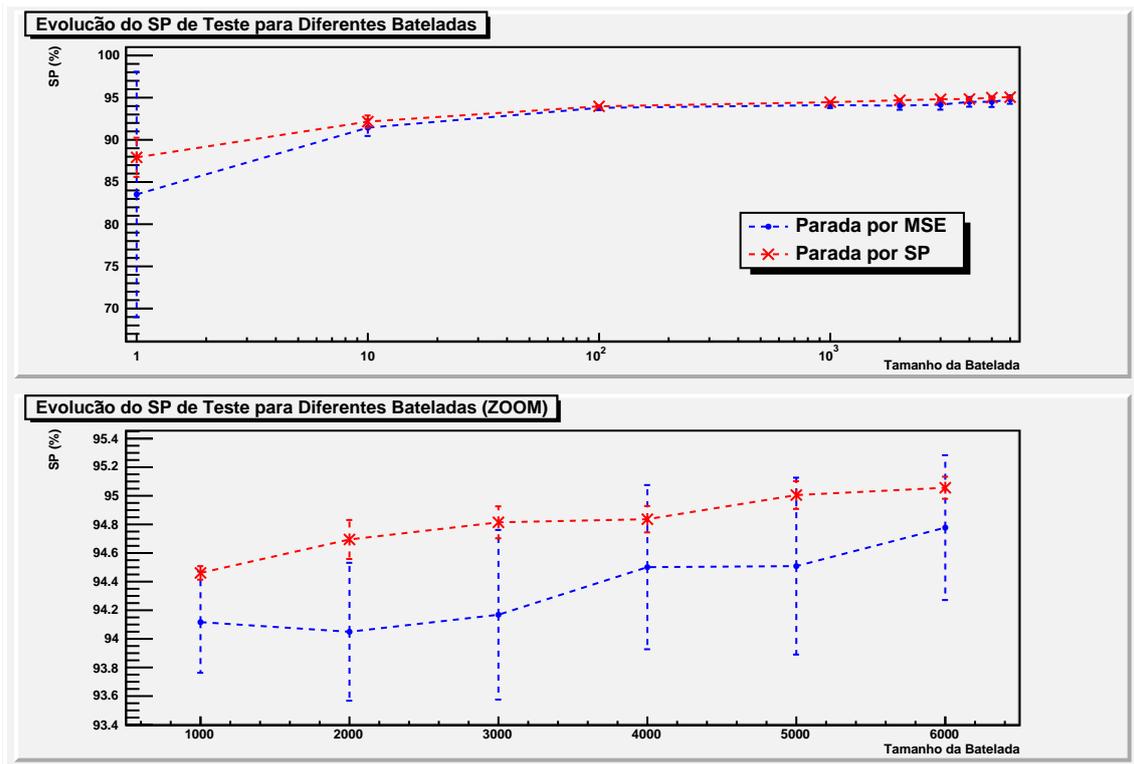


Figura 7.26: Variação do SP de teste de acordo com o tamanho da batelada.

SP. O produto SP [44] é definido por

$$SP = 100 \times \sqrt{\sqrt{P_e \times P_j} \times \frac{(P_e + P_j)}{2}} \% \quad (7.17)$$

onde P_e e P_j são as probabilidades de detecção de elétrons e jatos, respectivamente. Quanto maior o SP, maior a probabilidade de detecção de elétrons e menor será o falso alarme correspondente.

Enquanto que um critério de parada por MSE visa encontrar o ponto onde a saída da rede neural fica o mais parecida possível com o alvo especificado, o SP procurará indicar ao processo de treinamento o ponto onde a distinção máxima entre classes é obtido, sendo este critério mais apropriado para redes neurais destinadas à reconhecimento de padrões.

Uma rede neural foi treinada variando-se o tamanho da batelada. Para cada tamanho de batelada, 10 redes com mesma topologia, porém com inicializações distintas dos pesos, foram treinadas. Em cada treinamento, um número suficientemente grande de épocas (30.000) foi adotado para garantir a estabilização da figura de mérito (SP ou MSE) empregada no treinamento.

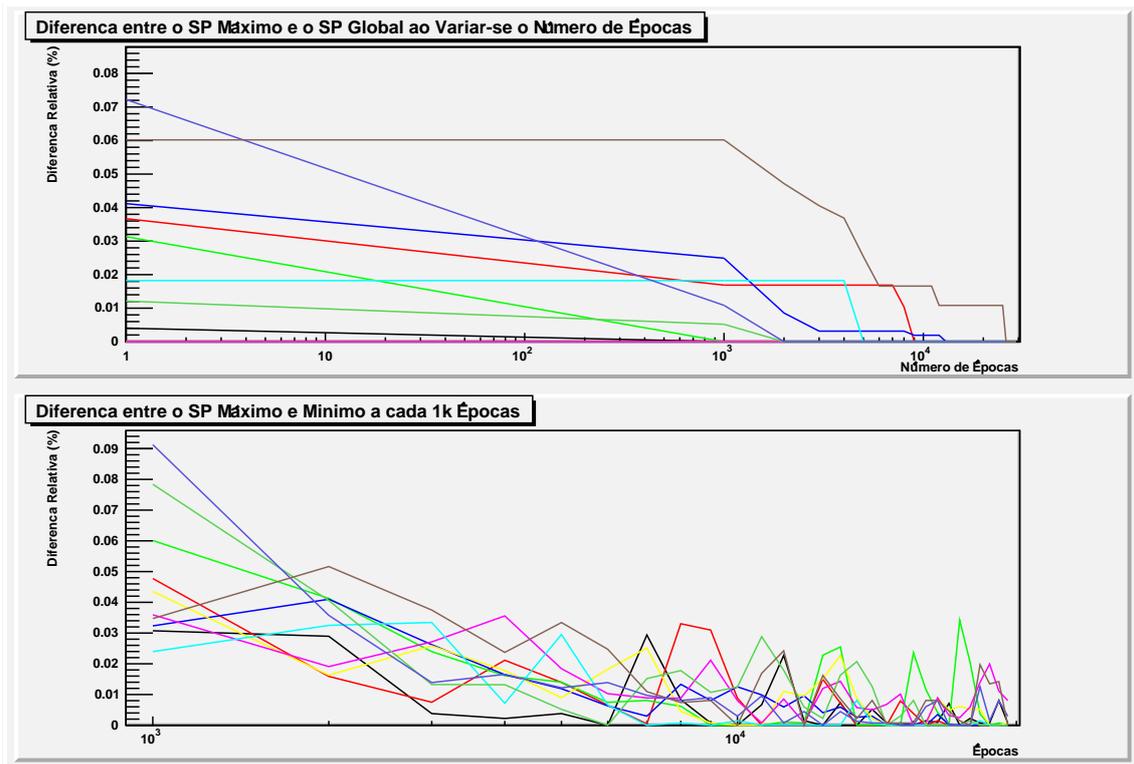


Figura 7.27: Variação do SP de teste de acordo com o número de épocas de treinamento.

É apresentado, na Figura 7.26, o comportamento do SP obtido a partir do conjunto de validação, ao variar-se o tamanho da batelada em cada treino, usando-se o MSE e o SP como figuras de mérito. Observa-se que a validação do treinamento por SP apresenta resultados ligeiramente melhores do que o MSE. Adicionalmente, o critério de parada por SP produziu, para uma mesma batelada, uma variância consideravelmente menor do que o critério de parada por MSE, como pode ser visualizado nas barras de erro de cada caso. Por fim, observa-se que a eficiência da rede também melhora quando aumenta-se o tamanho da batelada, uma vez que, com uma batelada maior, a rede consegue estimar a direção do vetor gradiente com maior confiabilidade.

Para estimar o número ótimo de épocas, foi analisada a evolução do treinamento para o melhor caso obtido (6.000 eventos por batelada e critério de parada por SP). O gráfico na parte superior da Figura 7.27 apresenta a diferença relativa entre o SP máximo obtido ao final das 30.000 épocas e o SP máximo obtido a cada 1.000 épocas. A análise desta figura permite concluir que, após 10.000 épocas, a diferença relativa é de apenas 0,02%. Já o gráfico na parte inferior da Figura 7.27

Tabela 7.4: Valores utilizados para cada parâmetro do treinamento neural.

Parâmetro	Valor
Figura de mérito	SP máximo
Tamanho da batelada	6.000 eventos por classe
Número de épocas	10.000
Critério de parada	Máximo número de épocas

apresenta a diferença relativa entre o SP máximo e o mínimo encontrados em cada bloco de 1.000 épocas (1-1.000, 1.001-2.000, 2.001-3.000, etc.). Com esta análise pode-se observar que, após 10.000 épocas, a diferença entre os SP máximo e mínimo em cada bloco é muito pequena ($< 0,01\%$), e permanece razoavelmente constante entre um bloco e outro, indicando uma estabilização do treinamento. Desta forma, decidiu-se que 10.000 épocas é um valor seguro para garantir a convergência do treinamento. Com isso, a Tabela 7.4 apresenta os valores utilizados para cada parâmetro de treinamento.

7.3.3 Análise da Flutuação Estatística

Para que a flutuação estatística inerente aos dados empregados possa ser levada em consideração na composição dos resultados, todos os classificadores desenvolvidos serão analisados pela validação cruzada [83]. Neste trabalho, a validação será feita conforme o seguinte algoritmo:

1. Divide-se todo o conjunto de elétrons e jatos em 12 blocos com igual número de eventos em cada um.
2. Para cada treinamento do classificador:
 - (a) Sorteia-se, para cada classe, 6 blocos para compor o conjunto de treinamento, e 6 blocos para compor o conjunto de validação/teste.
 - (b) O classificador neural é treinado⁶.
 - (c) Os resultados obtidos com o classificador desenvolvido são armazenados.

⁶Se o classificador for alimentado com eventos pré-processados por alguma técnica baseada na

Ao final de N sorteios, torna-se possível estimar a flutuação do modelo desenvolvido. Ao longo deste trabalho, a validação cruzada será feita empregando-se $N = 10$ sorteios.

7.3.4 Apresentação das Eficiências de Classificação

Ao longo deste trabalho, a eficiência de classificação obtida com um dado discriminador será apresentada através da curva ROC [81]. A curva ROC apresentada será a média das 10 ROCs produzidas ao longo dos 10 sorteios realizados pela validação cruzada. Além da curva ROC, será apresentada a média do SP máximo obtido em cada uma das 10 ROCs. Por fim, será apresentada, também, a média da taxa de falso alarme obtida para uma probabilidade de detecção de 97,34%⁷, calculada para cada uma das 10 ROCs produzidas pela validação cruzada. Tanto para o SP, como para o falso alarme, a margem de erro corresponde ao desvio padrão obtido para cada uma destas grandezas, após os 10 sorteios realizados pela validação cruzada.

A eficiência também poderá ser apresentada como a variação da probabilidade de detecção, ou do falso alarme, em função de E_T , η e ϕ . Nestes casos, a margem de erro será calculada como $100/\sqrt{N}$, onde N é o número de eventos contidos em cada região analisada ao longo da faixa dinâmica de E_T , η e ϕ .

estatística dos eventos (PCA, ICA, etc.), os parâmetros de pré-processamento deverão, tal como a rede neural, ser recalculados a cada sorteio.

⁷Esta é a probabilidade de detecção do T2Calo (veja a Seção 5.4.2) para o conjunto de dados empregado.

Capítulo 8

Resultados com Dados de Simulação

Com o conhecimento especialista adquirido, torna-se possível a utilização de técnicas de pré-processamento que permitam a extração de componentes que representem claramente a distinção entre elétrons e jatos. Os componentes selecionados favorecerão o desenvolvimento de um classificador mais simples para o processo de discriminação, ao passo que permitirão manter uma alta eficiência de detecção.

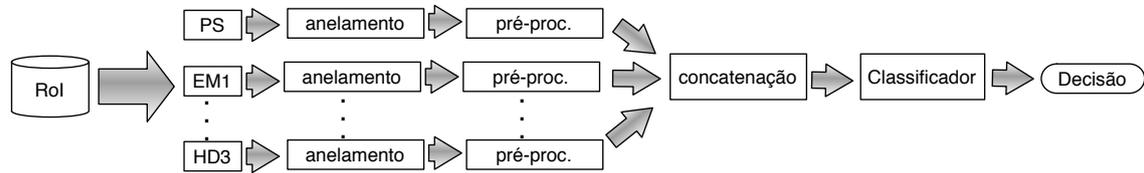
Este capítulo apresentará os resultados obtidos ao projetar-se os sinais simulados nos componentes principais (PCA) e de discriminação (PCD), de forma a verificar o desempenho destas duas técnicas, utilizando dados simulados de última geração. Adicionalmente, a correlação não linear existente entre os anéis será explorada através da análise de componentes independentes (ICA).

O conhecimento adquirido sobre a geração dos eventos utilizados neste trabalho fornece fortes indícios de que o modelo básico de ICA, para os anéis, não é atendido, visto que temos, provavelmente, mais sensores do que fontes independentes. Desta forma, a PCA contribuirá para que o número correto de fontes independentes possa ser determinado. Para a estimação do número correto de fontes independentes, cortes mais relaxados em energia serão feitos via PCA, e a identificação dos componentes independentes mais relevantes à classificação será feita por análise de relevância, em um processo chamado de *Análise de Componentes Independentes Relevantes* (RICA).

A análise via PCD, como um pré-processamento a ser realizado antes da análise



(a) Não Segmentado



(b) Segmentado

Figura 8.1: Fluxo de processamento para ambas abordagens.

de componentes independentes, também pode ser empregada para a seleção de fontes independentes com forte potencial de discriminação. Neste caso, a PCD pode ser capaz de reduzir o problema a poucos componentes de grande relevância para a discriminação, ao passo que a ICA se encarregaria de realizar a decorrelação não linear entre eles, tornando esta distinção ainda mais clara para o classificador.

Uma vez que as análises deste capítulo visam a classificação elétron / jato no âmbito do segundo nível de filtragem, deve-se trabalhar com eventos que reflitam, o máximo possível, a realidade do L2. Desta forma, neste capítulo, todas as análises serão realizadas com dados obtidos com o corte e15i do L1. Por fim, todos os anéis serão normalizados pela energia total contida nos mesmos, tal como discutido no Capítulo 7.

8.1 Abordagens para a Extração de Características

Conforme descrito no Capítulo 3, cada camada do calorímetro eletromagnético e hadrônico possui uma característica própria, o que pode tornar a análise de cada camada isoladamente (abordagem segmentada) mais vantajosa. Por outro lado, ao explorar-se as relações existentes entre as camadas, analisando os 100 anéis como um todo (análise não segmentada), maiores índices de compactação da informação podem ser atingidos. A Figura 8.1 apresenta o fluxo de processamento para cada

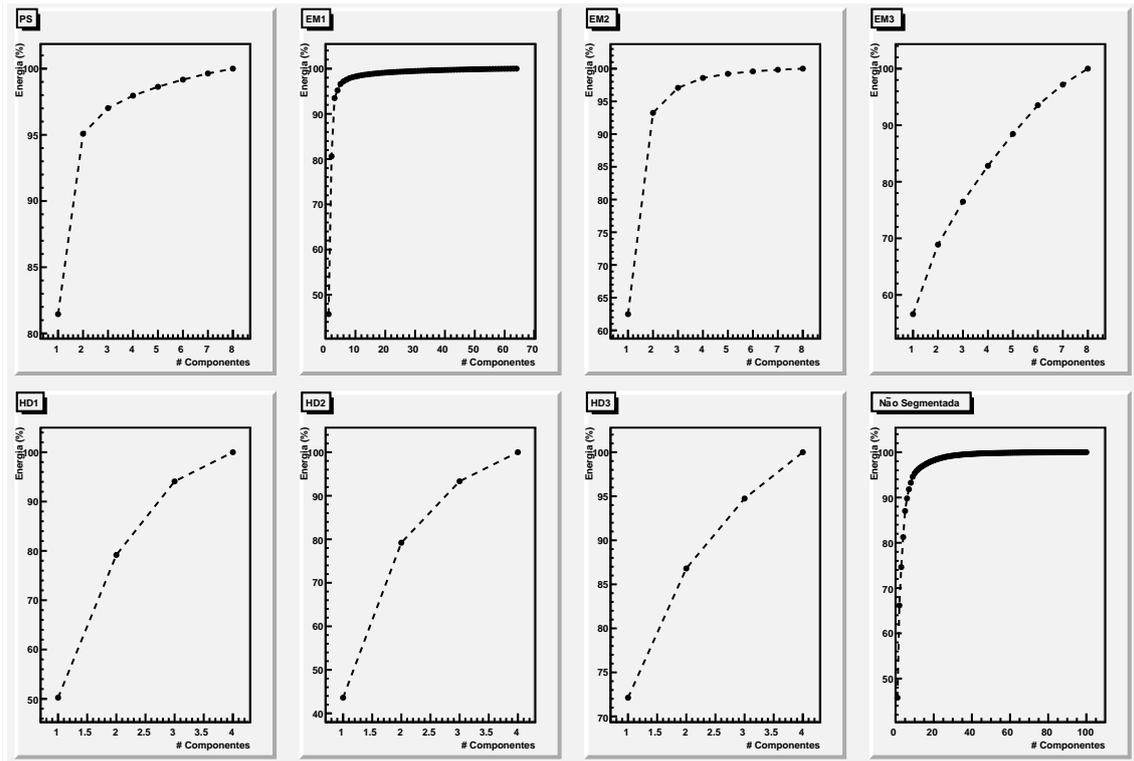


Figura 8.2: Curva de carga obtida após a extração dos componentes principais (abordagem segmentada e não segmentada).

abordagem. Para o caso não segmentado (Figura 8.1a), os anéis produzidos em cada camada são concatenados para que sejam pré-processados conjuntamente, antes de alimentarem o discriminador. Na análise segmentada (Figura 8.1b), o pré-processamento ocorre isoladamente para os anéis de cada camada. O resultado obtido em cada segmento é, então, concatenado para alimentar o bloco de classificação.

8.2 Análise por Componentes Principais (PCA)

A primeira abordagem para o pré-processamento consiste em tentar minimizar possíveis correlações lineares entre os anéis. Com informações descorrelacionadas, torna-se mais fácil isolar componentes que representam a informação útil para o problema de discriminação.

É apresentado, na Figura 8.2, a curva de carga obtida após a extração dos componentes principais, a partir da matriz de covariância, de maneira segmentada e não segmentada. Nota-se, para o caso não segmentado, e para o PS, EM1 e EM2 da

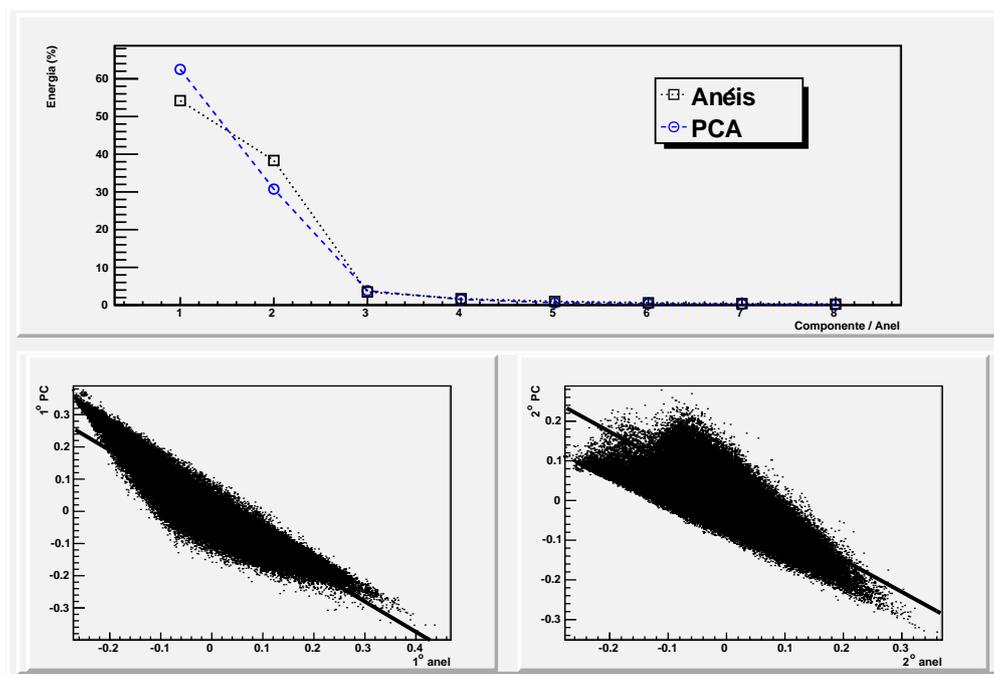


Figura 8.3: Quantidade (em valores percentuais) de variância retida, para a EM2, pelos anéis, e por seus componentes principais (em cima) e a distribuição bidimensional entre os 2 primeiros anéis e os 2 primeiros componentes principais (embaixo). As linhas contínuas representam a melhor aproximação linear para os dados.

abordagem segmentada, que a cauda da curva de carga é bem rápida, com a energia rapidamente se concentrando nos primeiros componentes, o que é condizente com o fato destas camadas serem de grande absorção. Entretanto, mesmo em sua base original, os primeiros anéis já, naturalmente, concentram mais energia (variância) do que os anéis mais externos. Como exemplo, a Figura 8.3 apresenta, para a EM2, a quantidade de variância (em valores percentuais) retida por cada anel, e pelos componentes principais extraídos a partir desta camada. Nota-se que a análise de componentes principais restringe-se a compactar a informação presente apenas nos primeiros anéis desta camada, não realizando nenhum ajuste na concentração de energia retida pelos anéis mais externos, indicando a presença de correlações apenas entre os primeiros anéis. Adicionalmente, a Figura 8.3 apresenta, como referência, os histogramas bidimensionais comparando o primeiro anel com o primeiro componente, e o segundo anel com o segundo componente, mostrando que a projeção nestes dois componentes não se afasta de maneira extrema dos anéis em sua base original. Entretanto, esta concentração nos primeiros componentes seria menor caso uma

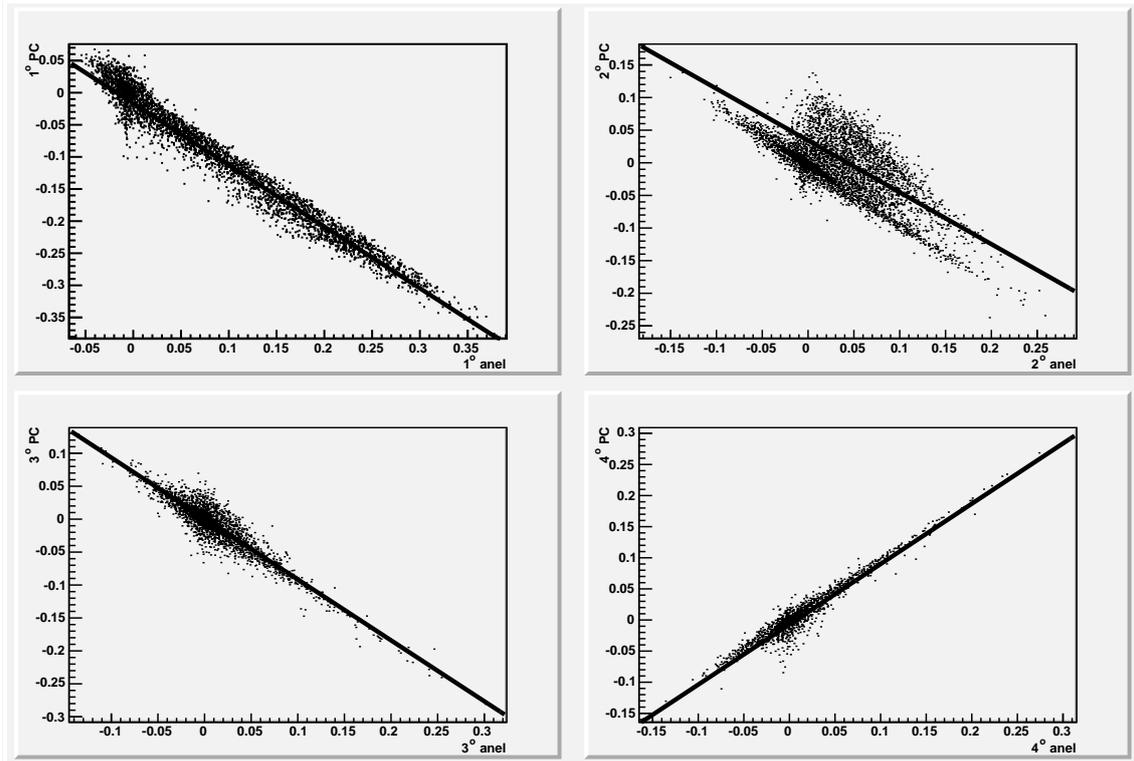


Figura 8.4: Correlação bidimensional, para a HD3, entre os anéis em sua base canônica e projetados na base de componentes principais. As linhas contínuas representam a melhor aproximação linear para os dados.

normalização que realçasse o perfil lateral dos chuviros, tal como a normalização sequencial, fosse adotada.

Ao observar-se a curva de carga das camadas EM3, HD1, HD2 e HD3, nota-se o comportamento inverso. A cauda da curva de carga é bem mais lenta, indicando que os anéis já se encontram naturalmente descorrelacionados. Isto indica que, para estas camadas, a projeção em seus componentes principais alterará pouco o valor destes anéis. No caso da EM3, como ela foi concebida para absorver eventos que incidiram com energia suficiente para não serem completamente absorvidos pelas camadas anteriores, ela praticamente só contém ruído na maior parte dos eventos, o que faz com que a sua curva de carga seja quase igual às curvas de carga observadas para as camadas hadrônicas.

Observa-se, na Figura 8.4, os gráficos de correlação bidimensional entre os anéis, da HD3, na base original, e projetados em seus componentes principais, onde é possível observar a baixa flutuação existente nas distribuições.

Ao observar-se que a informação encontra-se muito concentrada em poucos com-

ponentes, torna-se possível compactar o sinal da entrada através do corte de componentes que retenham pouca energia, provavelmente associada à informação descorrelacionada, proveniente de ruído de fundo. Para a seleção de componentes, foi adotado o corte segundo o critério de *Average Root* [86]. Este critério estabelece que um dado componente principal \mathbf{w}_i deve ser selecionado somente se o seu respectivo autovalor λ_i satisfizer a relação

$$\lambda_i > 0,7 \times \bar{\lambda} \quad (8.1)$$

onde $\bar{\lambda}$ é a média dos autovalores associados aos componentes principais extraídos.

Conforme dito na introdução deste capítulo, a análise de componentes principais será empregada para compactar a informação de entrada, antes da extração das fontes independentes. Entretanto, não se sabe, ao certo, qual o melhor número de componentes que dever ser extraído. Desta forma, este problema será abordado realizando, também, cortes, em energia, menos rigorosos do que o proposto pelo critério *Average Root*, e, através da análise da relevância de discriminação de cada componente (vide a Seção 8.5), fazer a seleção final dos componentes mais relevantes. Assim sendo, dois cortes, além do *Average Root*, foram propostos: um corte mais relaxado, retendo 99% da variância do sinal, e um corte mais rigoroso, retendo 97% da energia do processo. A Tabela 8.1 apresenta, para cada um dos 3 critérios de corte abordados, o número de componentes selecionados. Para o caso do *Average Root*, apresenta-se, também, a quantidade de energia retida por esta estratégia.

São apresentados, na Figura 8.5, os resultados obtidos ao alimentar-se um classificador neural com a projeção nos componentes principais extraídos de forma segmentada e não segmentada, ao descartarem-se os componentes menos energéticos de acordo com os 3 critérios de corte apresentados na Tabela 8.1. Observa-se que, a análise segmentada apresenta resultados sempre melhores quando comparados à abordagem não-segmentada. A diferença entre ambas as abordagens fica mais explícita conforme o corte de componentes aumenta, mostrando que, com uma compactação mais intensa do espaço de entrada, a análise segmentada consegue reter mais informação útil à classificação do que a análise não segmentada. Nota-se, que a redução de 1% na energia de cada camada apresentou o melhor resultado, superior à versão empregando anéis puros, mostrando que este 1% de informação descartada

Tabela 8.1: Número de componentes retidos para cada critério de seleção.

(a) Corte em 99% da energia.

Abordagem	Segmentada								Não Segmentada
Camada	PS	EM1	EM2	EM3	HD1	HD2	HD3	Total	Total
# Comp.	6	18	5	8	4	4	4	49	36

(b) Corte em 97% da energia.

Abordagem	Segmentada								Não Segmentada
Camada	PS	EM1	EM2	EM3	HD1	HD2	HD3	Total	Total
# Comp.	3	6	3	7	4	4	4	31	15

(c) Corte por *Average Root*.

Abordagem	Segmentada								Não Segmentada
Camada	PS	EM1	EM2	EM3	HD1	HD2	HD3	Total	Total
# Comp.	2	5	2	2	2	2	1	16	10
% Energia	95,1	96,6	93,2	68,9	79,2	79,2	72,1	N/A	95,3

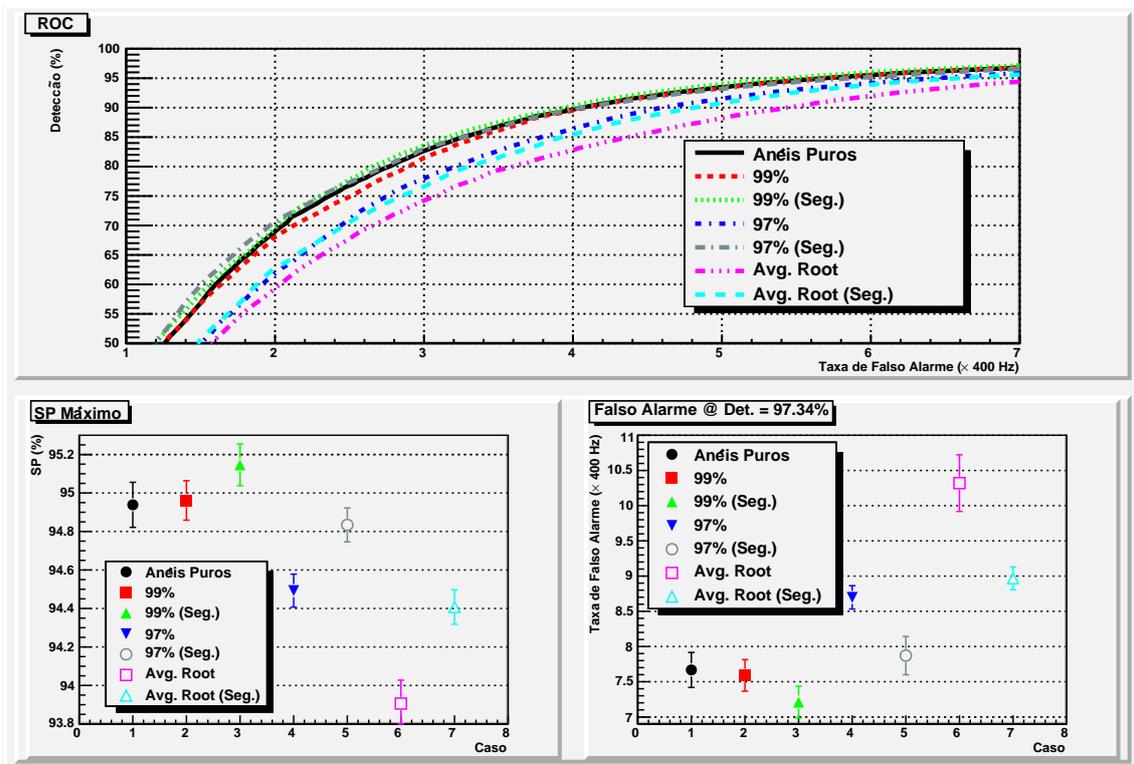


Figura 8.5: Resultados de classificação neural obtidos para diferentes percentuais de cortes em energia via PCA.

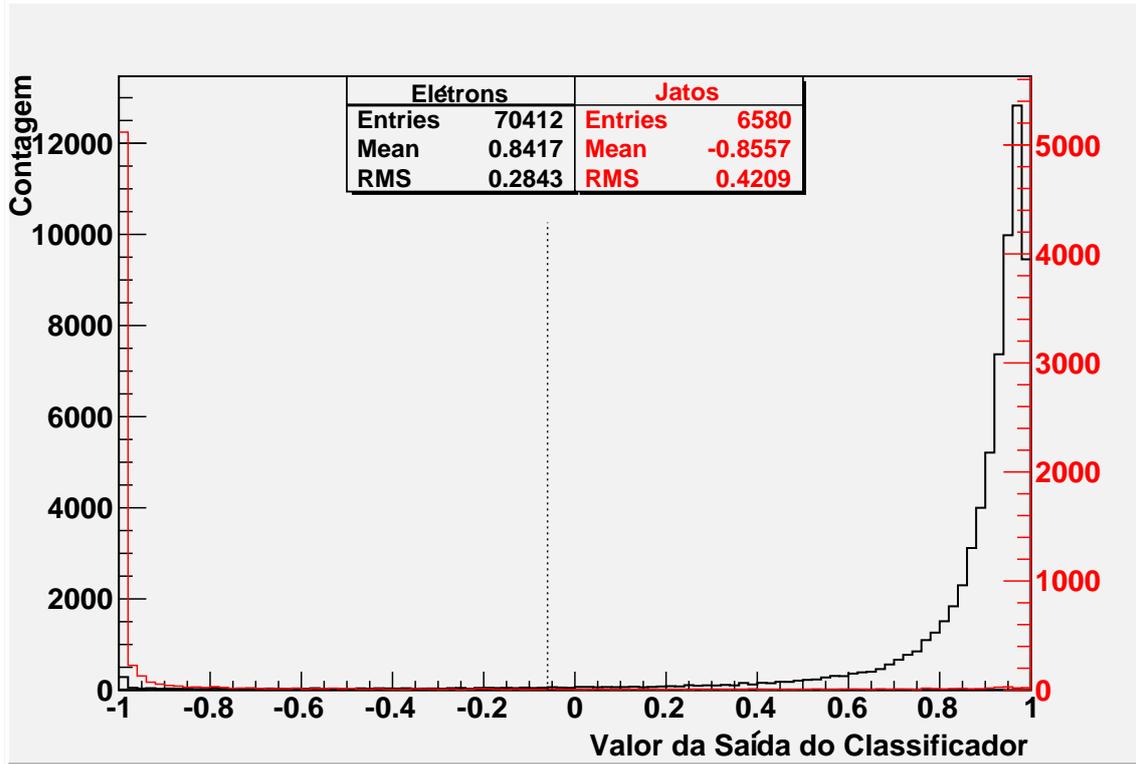


Figura 8.6: Distribuição da saída do classificador alimentado com os componentes principais segmentados compactados à 99% da energia do evento. A linha pontilhada representa o limiar de corte que provê o máximo SP.

era proveniente de ruído de fundo, não relevante à classificação. Adicionalmente, ao eliminar-se 3% da informação de cada camada, reduzindo a dimensão final do evento em 69%, obteve-se um resultado praticamente igual ao que foi obtido quando nenhuma compactação foi realizada (anéis puros). Por fim, mesmo o pior resultado, obtido com a compactação não segmentada via *Average Root*, só provocou uma diminuição de $\sim 0,8$ ponto percentual no valor do SP máximo, com a vantagem de compactar em 90% a dimensão da entrada.

A Figura 8.6 apresenta a distribuição da saída do classificador alimentado com a projeção nos componentes principais extraídos de maneira segmentada, e compactados à 99% da variância de cada camada. Observa-se que o conjunto de jatos apresenta um desvio bem pequeno, ficando bastante concentrado em -1. Já o conjunto de elétrons, apresentou um perfil mais espalhado, porém posicionado, ainda assim, bem próximo de +1, indicando que o treinamento do classificador foi bem realizado. Já na Figura 8.7, apresenta-se a variação da eficiência de detecção e do falso alarme, em função de E_T e η . A eficiência em função de ϕ não será apresentada,

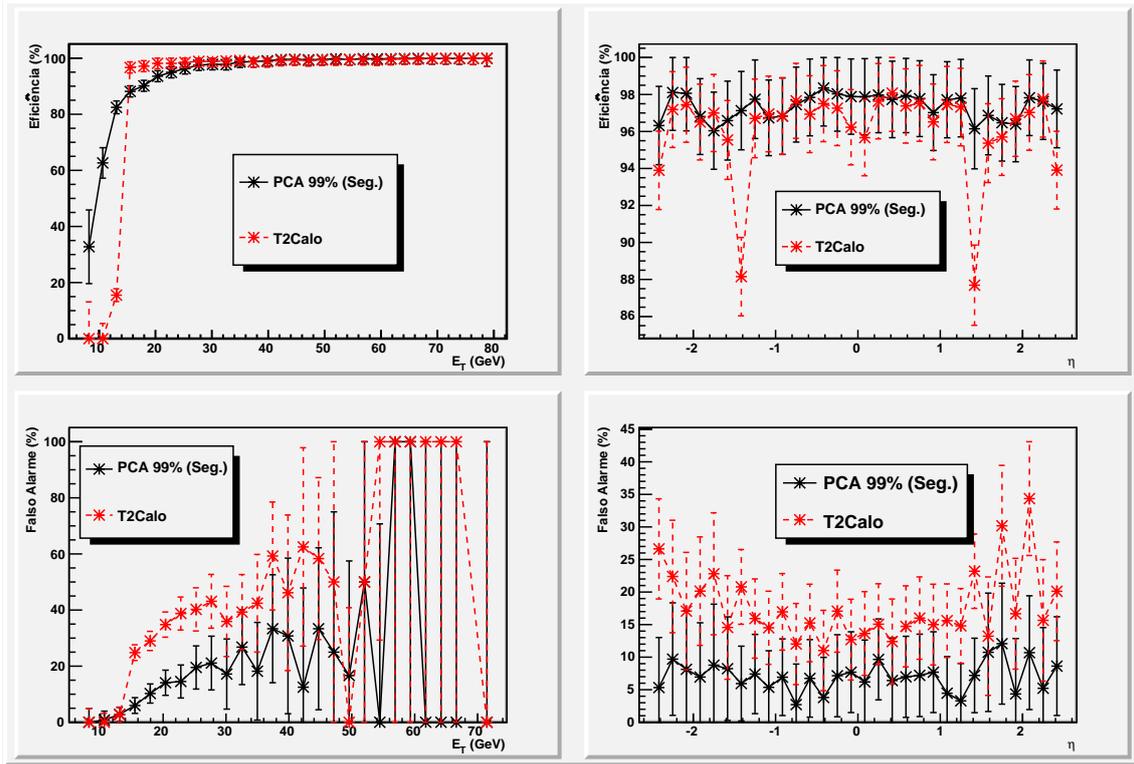


Figura 8.7: Variação da eficiência (em cima) e do falso alarme (embaixo) para o classificador alimentado com os componentes principais segmentados compactados a 99%, em função de E_T e η .

visto que, dada a uniformidade do ATLAS ao longo desta coordenada, os resultados obtidos não apresentam nenhuma particularidade que mereça uma análise mais profunda.

Em relação à energia transversa, nota-se que a versão do classificador neural alimentada por componentes principais é mais eficiente em baixas energias. Na região entre 15 e 25 GeV, o T2Calo oferece melhores valores de detecção de elétrons. Entretanto, na mesma faixa de energia, o falso alarme oferecido pelo T2Calo é quase o dobro do obtido pelo classificador neural. Isto deixa clara a priorização do T2Calo para a identificação de elétrons. Em relação à coordenada η , nota-se, para elétrons, que a rede neural é muito mais eficiente na região do *crack* do que o T2Calo. Nas outras regiões, a eficiência de ambos os algoritmos é similar. Entretanto, mais uma vez o falso alarme do T2Calo ao longo desta coordenada é substancialmente superior ao obtido pelo modelo baseado em componentes principais.

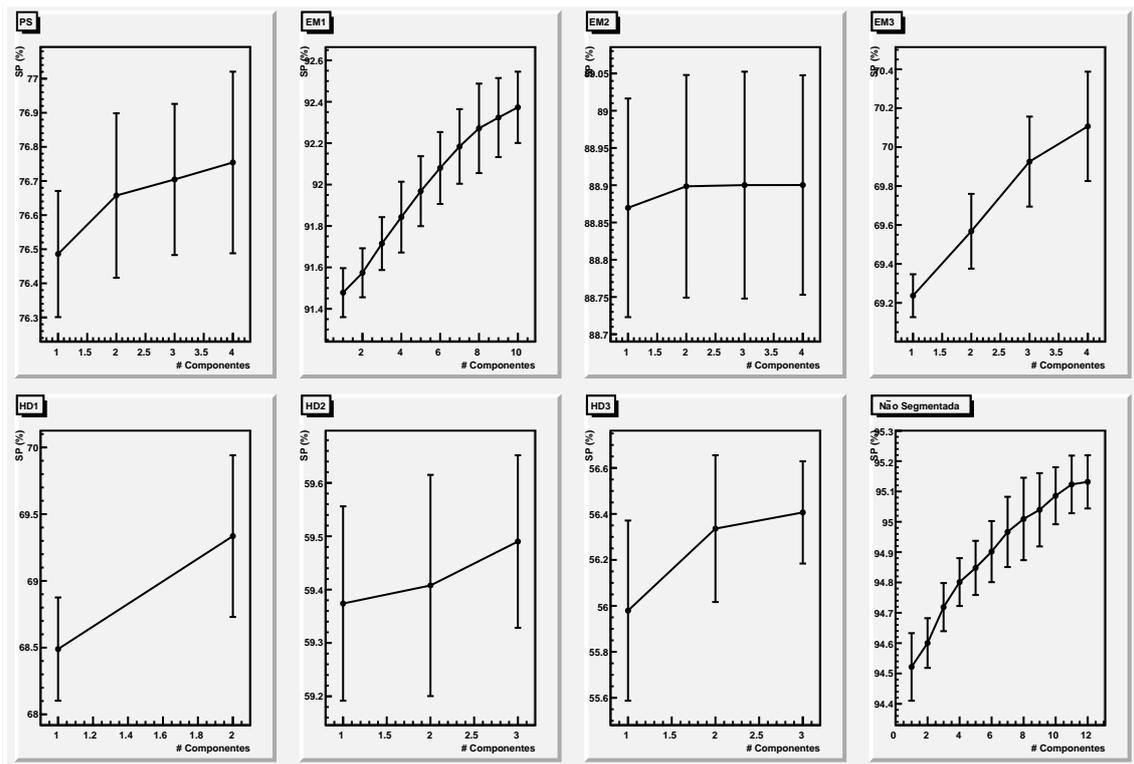


Figura 8.8: Evolução do SP de acordo com o número de componentes principais de discriminação extraídos do caso segmentado e não segmentado.

8.3 Análise por Componentes Principais de Discriminação

A análise de componentes principais de discriminação, tal como descrita no Apêndice A, pode ser uma boa opção a ser utilizada sobre os anéis topológicos para a identificação de características úteis à classificação. Adicionalmente, a PCD pode funcionar como um critério de pré-seleção de componentes, para a posterior extração de componentes independentes de superior capacidade de discriminação.

Observa-se, na Figura 8.8, a evolução do produto SP no decorrer da extração dos componentes principais de discriminação para o caso segmentado e não segmentado. A análise segmentada mostra que a EM1 é a camada onde mais se consegue extrair informação útil à discriminação, tendo em vista que foi esta camada que atingiu os valores mais altos de SP. Como esta camada é a que apresenta a mais fina granularidade em η , esta consegue avaliar melhor o perfil lateral do chuveiro produzido, o que se traduz em uma maior capacidade de discriminação. Não muito distante do SP da EM1, encontra-se o SP obtido para a EM2, que também resulta da fina

Tabela 8.2: Comparação entre o SP obtido utilizando-se informação de segmentos isolados.

Segmento	SP (PCD)	SP (T2Calo)
EM1	92,68	78,51
EM2	90,05	73,27
Sec. Had.	75,37	57,02

granularidade existente nesta camada. É curioso observar, entretanto, o fraco poder de discriminação das camadas hadrônicas, o que se justifica pelo corte com isolamento pelo L1. Conclui-se, para os eventos empregados nesta análise, que o perfil lateral dos chuveiros joga um papel mais importante do que a deposição de energia na seção hadrônica. Esta relevância maior do perfil lateral do chuveiro também é observada no T2Calo, quando se analisa, isoladamente, as variáveis de corte do T2Calo baseadas na EM1, EM2 e seção hadrônica (vide a Tabela 8.2). Tanto para o T2Calo, como para a PCD, a ordem de importância para a discriminação entre estes 3 segmentos é a mesma (EM1 \rightarrow EM2 \rightarrow Seção Hadrônica).

Conforme apresentado no Apêndice A, os componentes principais de discriminação também podem ser extraídos de maneira que sejam ortogonais entre si, de acordo com o algoritmo descrito na Seção A.2.1. Após a utilização desta técnica, são apresentadas, na Figura 8.9, as curvas com a evolução do produto SP conforme se aumenta o número de componentes principais ortogonais de discriminação. Nota-se, tanto no caso segmentado, quanto no caso não segmentado, que um único componente é suficiente, visto que o SP não evolui conforme se adicionam novos componentes. O motivo deste comportamento reside no fato de que, para esta técnica, os dados possuem apenas uma única direção discriminante (o primeiro componente). Uma vez que a informação contida na direção apontada pelo primeiro componente é removida do conjunto de dados, não resta mais nenhuma direção que possibilite uma boa distinção entre as classes, resultando em uma alta aleatoriedade da direção apontada pelos componentes posteriores ao primeiro.

Em ambas as técnicas de extração de componentes principais de discriminação, a seleção de componentes foi feita identificando-se, na curva de evolução do SP de cada caso apresentado nas Figuras 8.8 e 8.9, o número mínimo de componentes onde o último componente retido é capaz de conter, em sua barra de erro, o SP

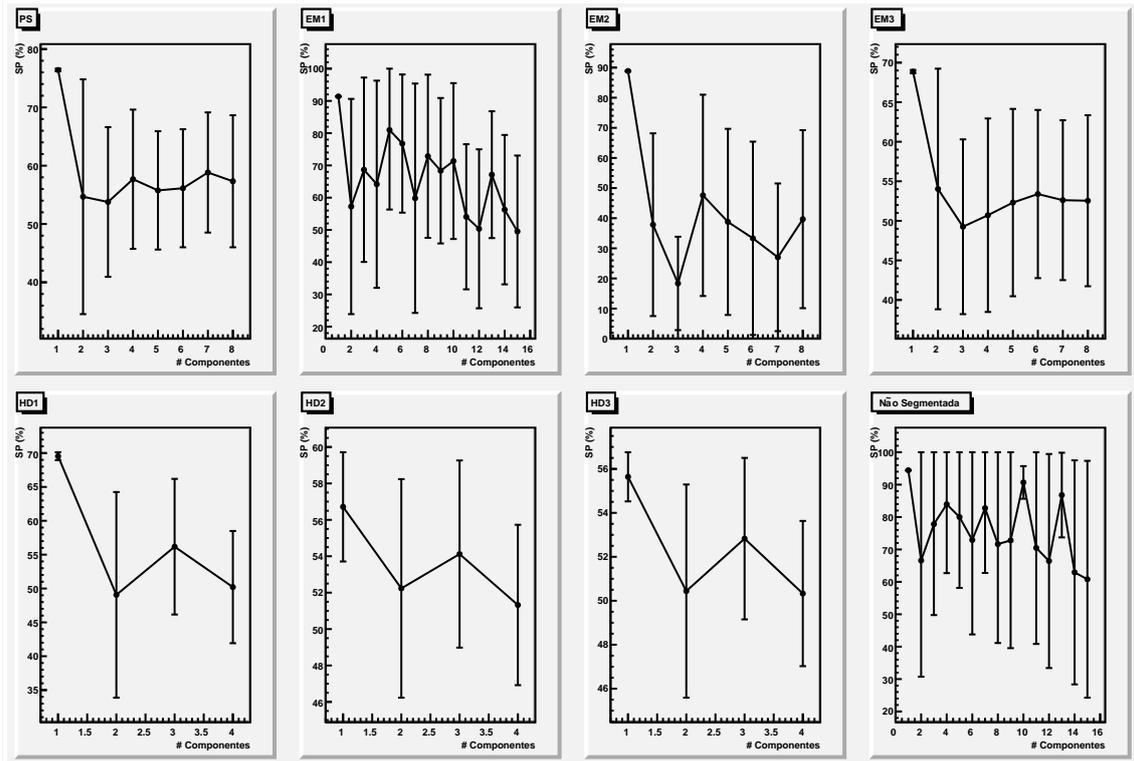


Figura 8.9: Evolução do SP de acordo com o número de componentes principais ortogonais de discriminação extraídos do caso segmentado e não segmentado.

máximo alcançado em cada camada. O número de componentes selecionados em cada extração é apresentado na Tabela 8.3, para ambos os métodos.

A Figura 8.10 apresenta os resultados obtidos para o classificador neural treinado com as projeções nos componentes principais de discriminação (ortogonais e não ortogonais) obtidos de maneira segmentada e não segmentada. Para a extração de PCDs não ortogonais, um SP máximo de 95%, para o caso não segmentado, foi obtido com apenas 8 componentes (8% da informação original), o que confirma a capacidade da PCD de extrair características que melhor distinguem ambas as classes. A abordagem segmentada provê melhores resultados para valores de falso alarme menores que 3%, entretanto, a eficiência de detecção para um falso alarme de 3% é de apenas 84%, o que é considerado baixo para os requisitos do sistema de filtragem do ATLAS. Tomando como referência a probabilidade de detecção do T2Calo (97,34%), a abordagem segmentada oferece um falso alarme $\sim 13\%$ superior ao obtido com a extração não segmentada. A abordagem não segmentada apresentou resultados discretamente melhores do que a versão empregando anéis puros, empregando apenas 8% da informação original. Porém, estes resultados podem ser

Tabela 8.3: Número de componentes principais de discriminação selecionados.

(a) PCD Ortogonal.

Abordagem	Segmentada								Não-Segmentada
Camada	PS	EM1	EM2	EM3	HD1	HD2	HD3	Total	Total
# Comp.	1	1	1	1	1	1	1	7	1

(b) PCD Não Ortogonal

Abordagem	Segmentada								Não-Segmentada
Camada	PS	EM1	EM2	EM3	HD1	HD2	HD3	Total	Total
# Comp.	2	8	1	3	2	1	2	19	8

considerados similares, visto que se encontram dentro da flutuação estatística do processo.

No caso dos componentes principais ortogonais de discriminação, os resultados obtidos foram piores do que os obtidos através da extração não ortogonal. Entretanto, vale ressaltar que, empregando apenas um componente para o caso não segmentado, esta abordagem ficou com um SP máximo apenas $\sim 0,6$ ponto percentual abaixo da abordagem via PCD não ortogonal, empregando apenas 1% da informação original. Para o caso segmentado, o resultado obtido com a PCD ortogonal ficou praticamente empatado com a respectiva versão não segmentada. Entretanto, analisando-se a curva ROC, nota-se que a abordagem segmentada, para valores de falso alarme menores que 3% apresentou resultados discretamente melhores do que a extração não segmentada dos componentes principais ortogonais de discriminação.

Para exemplificar o poder de discriminação dos PCD, a Figura 8.11 apresenta a projeção no primeiro PCA (à direita) e no primeiro PCD não ortogonal (à esquerda), ambos extraídos de maneira não segmentada. Caso um patamar de decisão fosse aplicado às projeções nestes primeiros componentes, a projeção no primeiro PCD atingiria um SP máximo de 94,66%. Por outro lado, a projeção no primeiro PCA proveria um SP máximo de 77,46%. Esta comparação evidencia que a PCD, dada a sua concepção, foi capaz de reter muito mais informação discriminante do que a PCA.

Dado que os componentes principais de discriminação não ortogonais apresentaram resultados superiores à extração com ortogonalização, a análise, daqui para frente, será realizada empregando-se apenas os componentes extraídos sem ortogo-

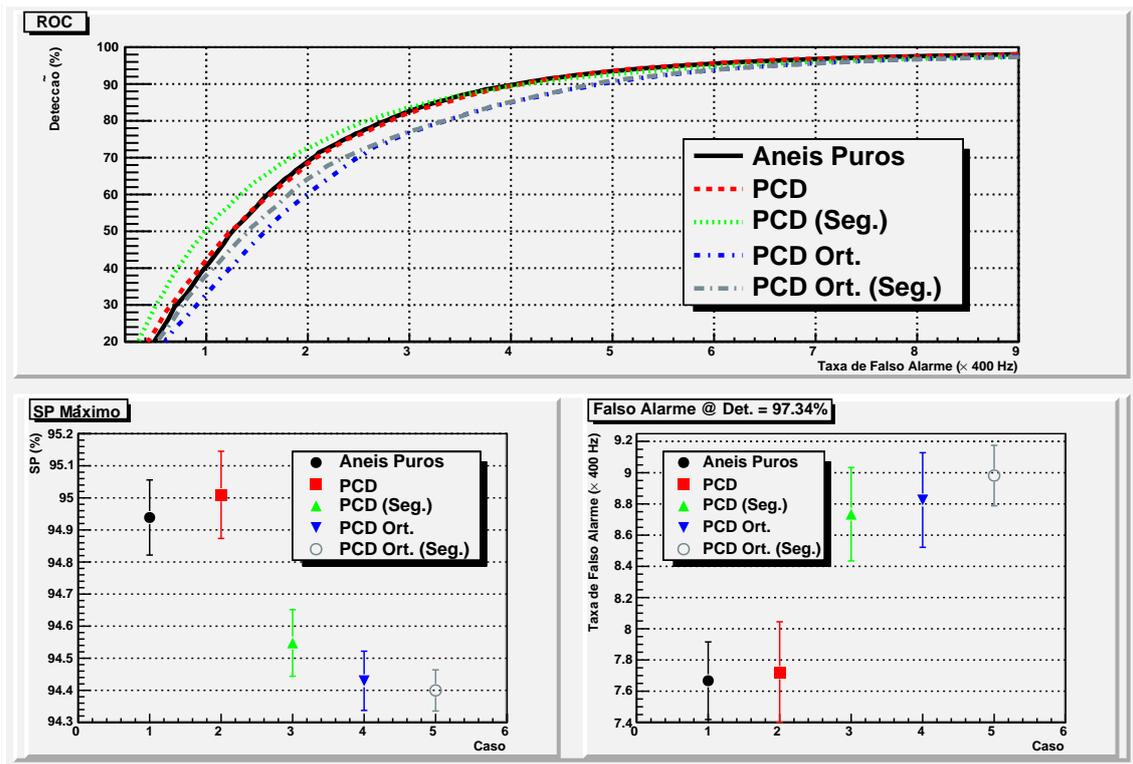


Figura 8.10: Eficiência de discriminação obtida com componentes principais de discriminação.

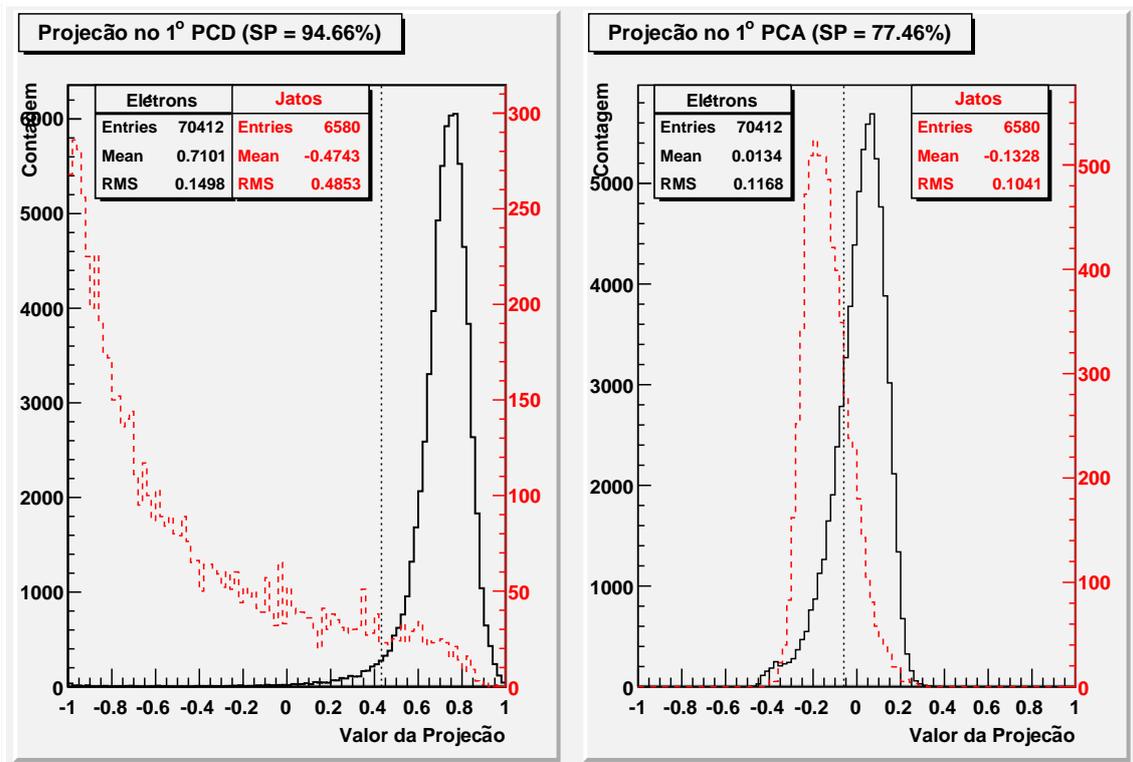


Figura 8.11: Projecção no primeiro PCA (à direita) e no primeiro PCD (à esquerda). A linha pontilhada representa o limiar de corte que proporciona o melhor produto SP.

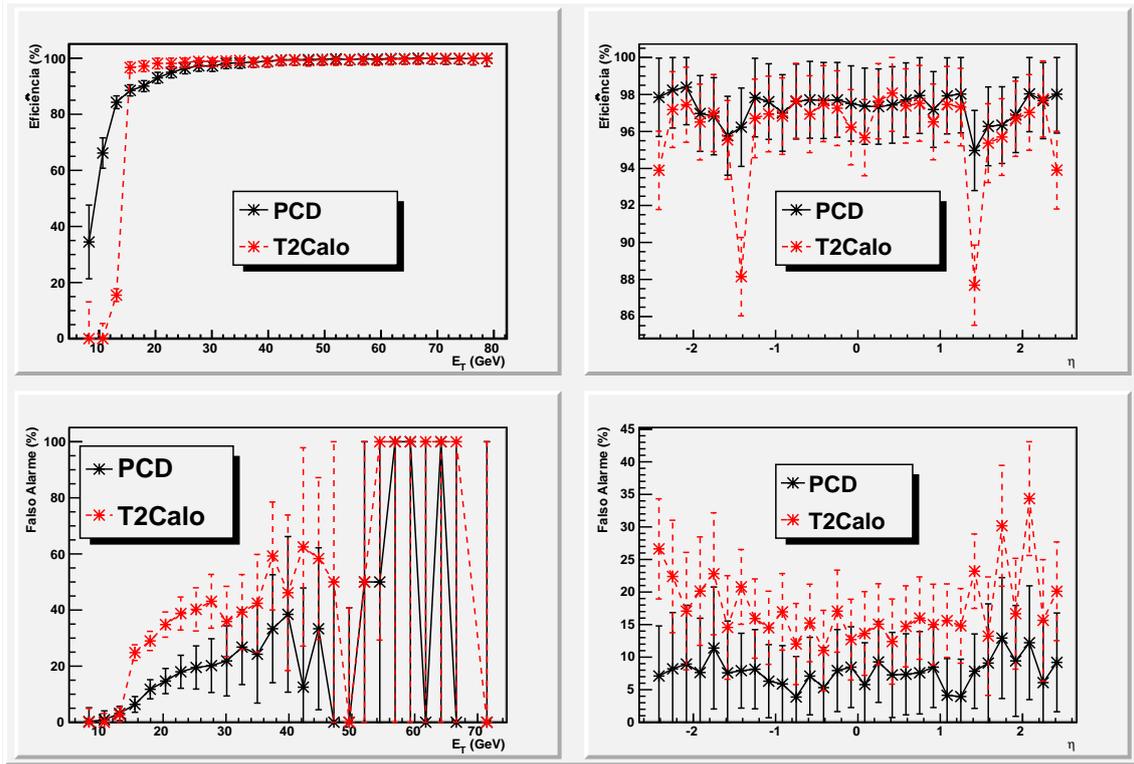


Figura 8.12: Variação da eficiência (em cima) e do falso alarme (embaixo) para o classificador alimentado com os componentes principais de discriminação, em função de E_T e η .

nalização.

É apresentado, na Figura 8.12 a variação da eficiência em função de E_T e η para o classificador desenvolvido a partir das projeções nos componentes principais (não ortogonais) de discriminação. Na mesma figura, a linha tracejada representa a mesma análise para o T2Calo. Os resultados mostram, novamente, que o modelo neural provê, em energia, resultados um pouco piores dos que os obtidos com PCA, ficando abaixo do T2Calo até aproximadamente 30 GeV. Em contrapartida, o falso alarme obtido pelo modelo baseado em PCD foi muito mais baixo do que o do T2Calo. O mesmo comportamento se observa para a variação do falso alarme com η . Para a detecção de elétrons ao longo de η , a PCD sofre um pouco mais de degradação em sua eficiência no *crack*, quando comparada à análise baseada em PCA. Mesmo assim, a PCD ainda foi bem mais resiliente do que o T2Calo nesta região.

8.4 Análise de Componentes Independentes

Para reduzir-se a dependência estatística entre os anéis, a análise de componentes independentes pode ser empregada. Para a extração dos componentes independentes, o algoritmo JADE [87] foi adotado.

Um problema com a análise de componentes independentes, é que o modelo básico de ICA presume que o número de fontes é igual ao número de sensores. No problema abordado neste trabalho, o número de sensores é conhecido, entretanto, não se pode precisar o número correto de fontes independentes. A partir do conhecimento sobre a física de produção dos eventos, pode-se dizer, com uma boa margem de certeza, que o número real de fontes independentes é menor do que a dimensão total dos anéis. Embora jatos possam produzir muitas combinações de eventos, muitos destes são rejeitados pelo L1, de forma que poucos destes processos físicos chegam ao L2. No que tange elétrons, o número de possibilidades também é restrito. Adicionalmente, o processo de desenvolvimento do chuveiro, seja eletromagnético ou hadrônico, apresenta grandes correlações, o que reforça a suposição da existência de poucas fontes independentes.

De fato, na Figura 8.13, são apresentados 4 exemplos de vetores de base de componentes independentes, estimados sem que nenhuma redução no número de sensores (anéis) fosse feita. Observa-se, para estas abordagens de exemplo, que os vetores da base possuem um único grande pico, e valores relativamente baixos para os outros anéis, indicando uma pobre estimativa do número correto de fontes independentes [87, 88].

Para compactar o espaço de entrada, a análise de componentes principais será utilizada. Conforme já mencionado na Seção 8.2, além do critério de corte via *Average Root*, 2 cortes em energia, suficientemente relaxados (99% e 97% da variância) serão empregados. Mais tarde, na Seção 8.5, os componentes retidos por estes dois cortes serão combinados com a análise da relevância de discriminação para que o número de fontes independentes possa ser estimado.

Por fim, dado que o problema em mãos é um problema de classificação, a utilização de componentes principais de discriminação também pode oferecer vantagens à análise de componentes independentes, visto que a PCD poderá ser capaz de isolar um número de fontes, que talvez sejam minoritárias em energia, mas muito relevan-

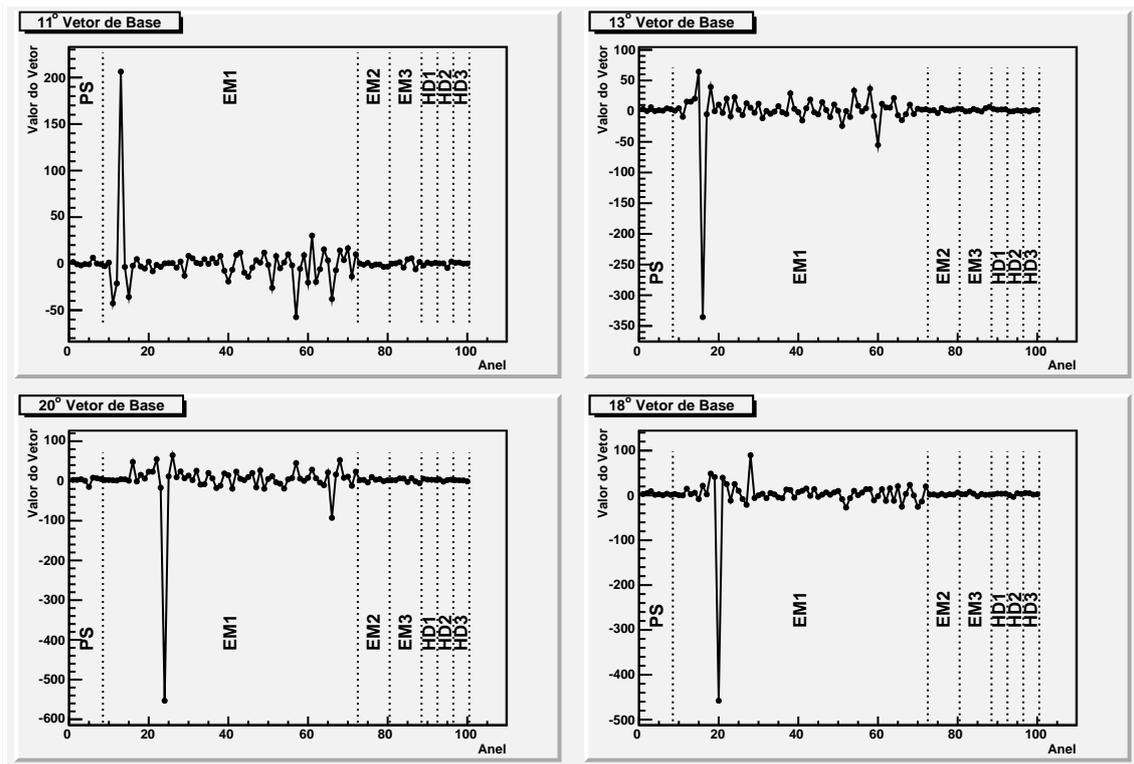


Figura 8.13: Exemplos de vetores da base de componentes independentes extraídos, de maneira não segmentada, a partir dos dados sem compactação.

tes para a classificação. Adicionando-se a decorrelação não linear proporcionada pela ICA aos componentes principais de discriminação extraídos, melhores índices de eficiência de classificação poderão ser obtidos, em comparação com a utilização das duas técnicas isoladamente.

8.4.1 Análise sem Compactação

Como referência, serão extraídos, os componentes independentes a partir dos anéis, sem qualquer redução na dimensão original. Desta forma, é apresentada, na Figura 8.14, a eficiência de classificação obtida para o classificador neural alimentado com a projeção nos 100 componentes independentes extraídos. Observa-se que, tanto a análise segmentada como a não segmentada obtiveram resultados ligeiramente piores do que o classificador neural alimentado com os anéis sem nenhuma projeção. Esta perda de eficiência, associada à análise dos vetores de base apresentados na Figura 8.13 deixa clara a necessidade de se reduzir o espaço de dados de entrada para que o o número de sensores se aproxime do número correto de fontes independentes

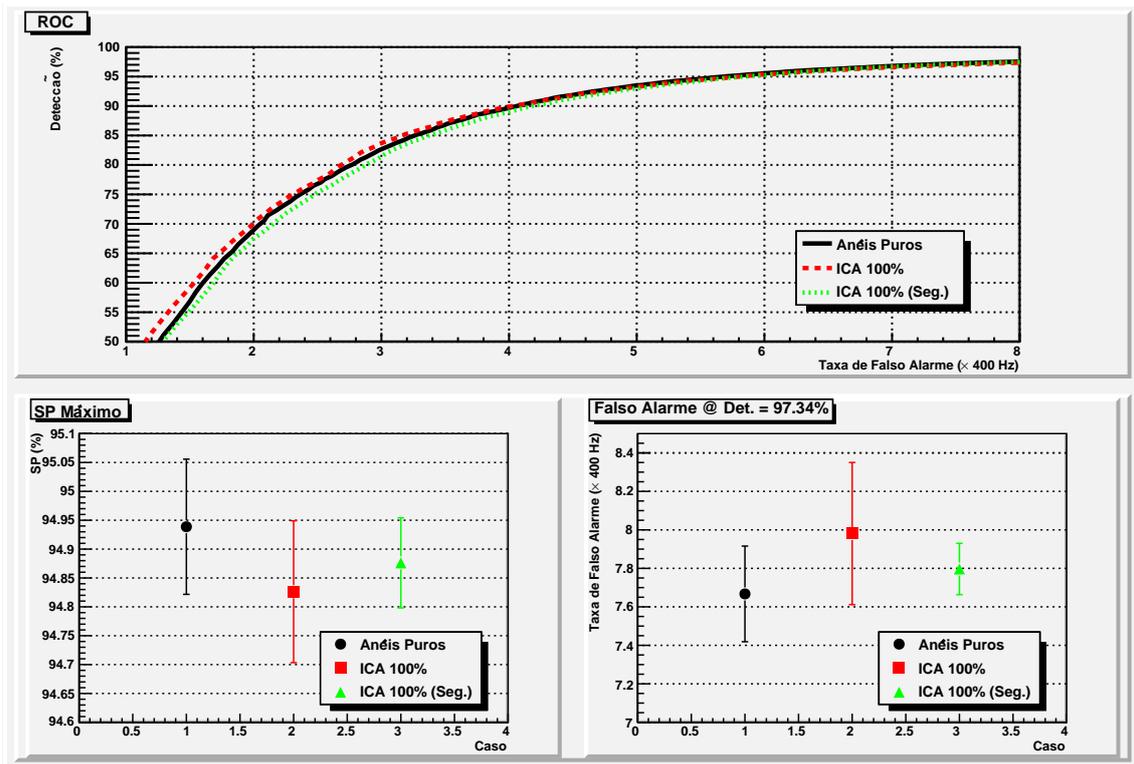


Figura 8.14: Resultados de classificação neural obtidos para a ICA baseada na dimensão total dos anéis.

a serem extraídas.

8.4.2 Compactação por PCA

Para se obter o número de fontes independentes, a dimensão original dos anéis foi compactada via PCA. Os mesmos 3 critérios de corte, apresentados na Tabela 8.1, foram empregados. O resultado do classificador treinado com os componentes independentes extraídos após a compactação via PCA é apresentado na Figura 8.15. Observa-se, para o caso não segmentado, que o descarte de apenas 1% da energia do sinal (reduzindo o número de fontes para apenas 36), permitiu que o resultado alcançado superasse o resultado obtido sem nenhuma projeção (anéis puros). Isto mostra que a diminuição do número de componentes permitiu uma melhor estimativa do número correto de fontes.

Para o corte em 1% da energia, a abordagem segmentada ficou empatada com a versão não segmentada. Como este mesmo corte apresentou, para a análise com componentes principais, melhores resultados do que a sua contrapartida não seg-

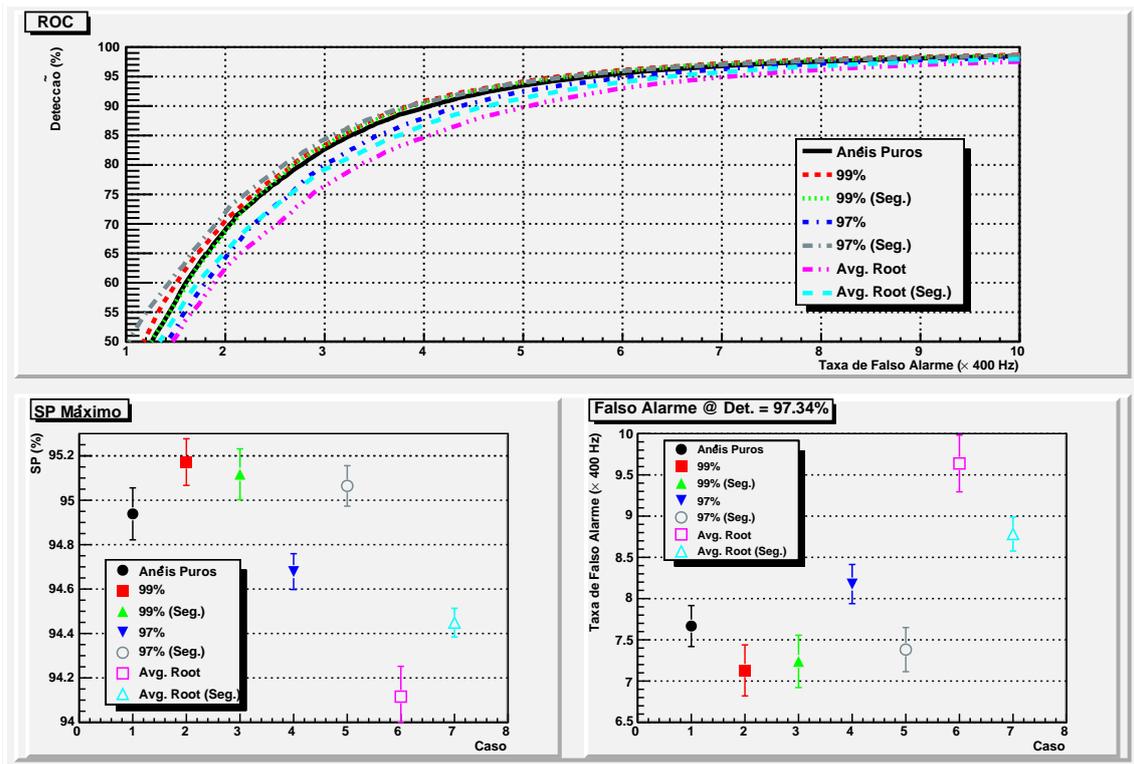
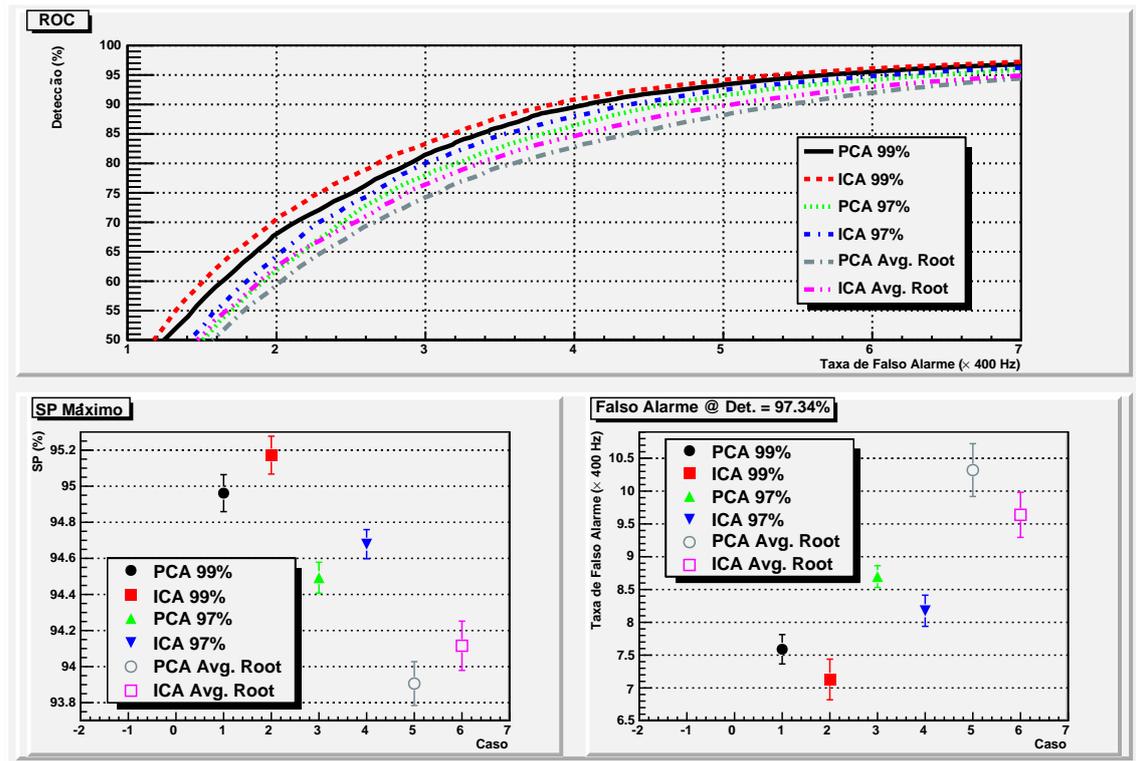


Figura 8.15: Resultados de classificação neural obtidos para a ICA baseada na compactação em energia dos anéis via PCA.

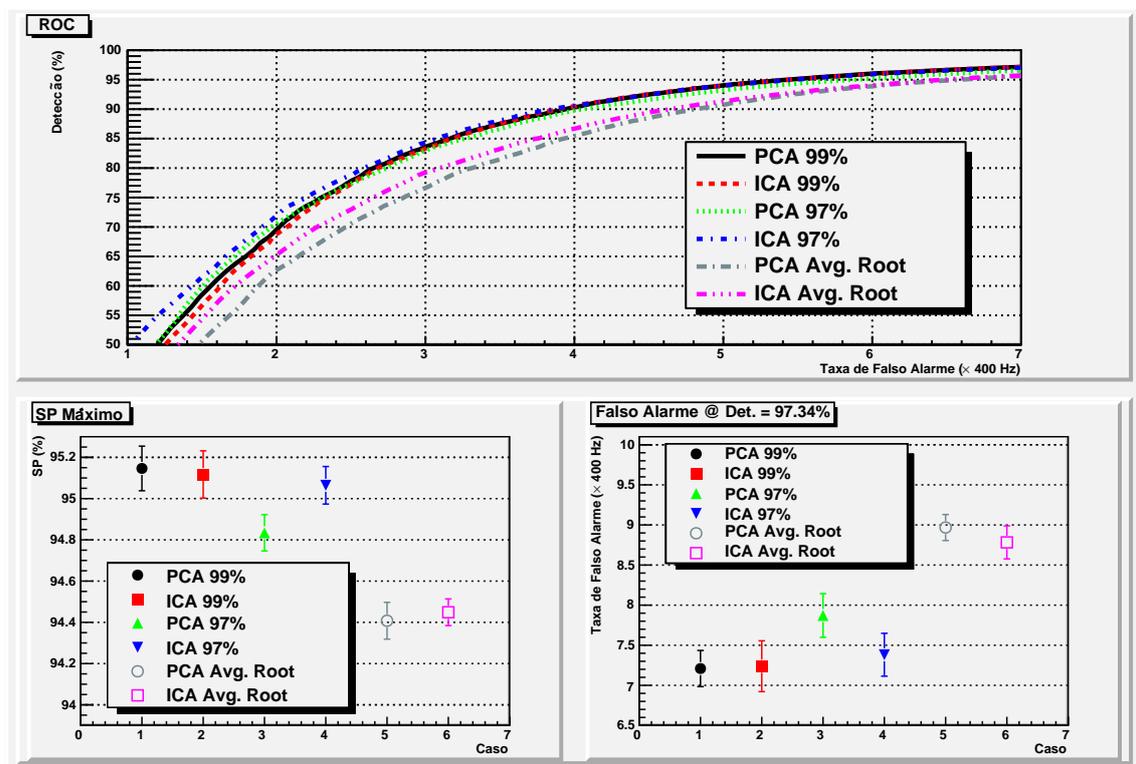
mentada, conclui-se que, a redução de apenas 1% na energia de cada camada não equilibrou adequadamente o número de fontes e sensores, resultando na extração distorcida dos componentes independentes, provocando uma ligeira degradação na eficiência de classificação.

Ao reter-se menos energia (97% e *Average Root*), a diferença entre a abordagem segmentada e não segmentada torna-se bem aparente. No caso segmentado, a redução de 3% da informação de cada camada (resultando num total de 31 fontes), conseguiu-se um resultado superior ao obtido utilizando-se os anéis puros. Para o caso não segmentado da abordagem retendo 97% da energia, e para o caso do *Average Root* (segmentado e não segmentado), nota-se que o corte em energia foi suficientemente intenso para descartar componentes relevantes à classificação, resultando em piores eficiências de classificação.

Para avaliar-se o ganho obtido com a decorrelação não linear dos anéis, em comparação à decorrelação linear proporcionada pela PCA, a Figura 8.16 apresenta a comparação entre as eficiências de classificação obtidas através da projeção nos componentes principais e nos componentes independentes. Para o caso não seg-



(a) Não Segmentado



(b) Segmentado

Figura 8.16: Comparação das eficiências de classificação obtidas através da projeção nos componentes principais e independentes.

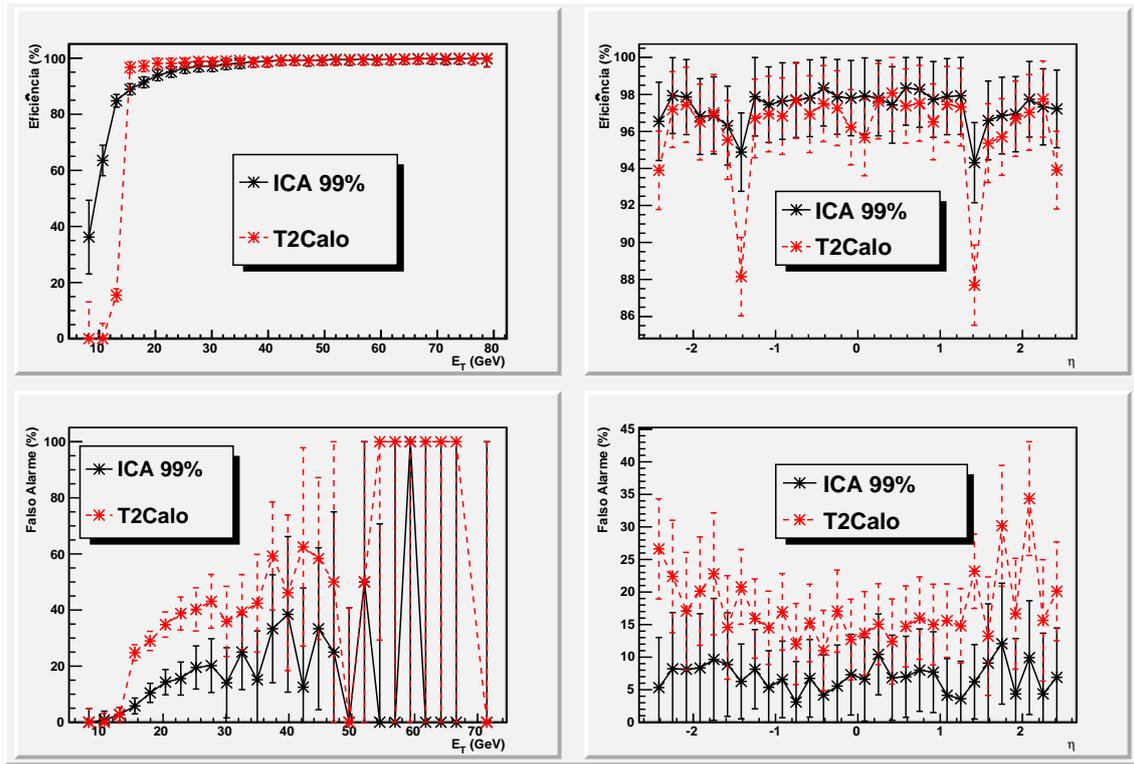


Figura 8.17: Variação da eficiência (em cima) e do falso alarme (embaixo) para o classificador alimentado com os componentes independentes extraídos após a projeção na base de componentes principais, compactada à 99% da informação.

mentado (Figura 8.16a), há uma clara vantagem obtida pela ICA para os casos onde a redução de energia foi de 1% e 3%. A projeção nos componentes independentes permitiu, mesmo com uma redução de 64% da dimensão do espaço de entrada, prover, para a mesma probabilidade de detecção, um falso alarme 6% menor do que a implementação por PCA retendo 99% da energia dos sinais.

Na comparação PCA \times ICA do caso segmentado (Figura 8.16b), a vantagem da ICA só aparece, efetivamente, para o caso onde se retém 97% da variância de cada camada. Para a abordagem empregando corte via o critério de *Average Root*, não houve vantagem efetiva na utilização da ICA, indicando que este corte mais abrupto pode ter sacrificado fontes independentes minoritárias em energia, porém relevantes à classificação.

É apresentada, na Figura 8.17, a variação da eficiência, em função de E_T e η do modelo desenvolvido utilizando componentes independentes extraídas após projeção não segmentada nos componentes que retém 99% da variância do sinal. Desta vez, nota-se uma ligeira melhora na eficiência de detecção de elétrons para a região

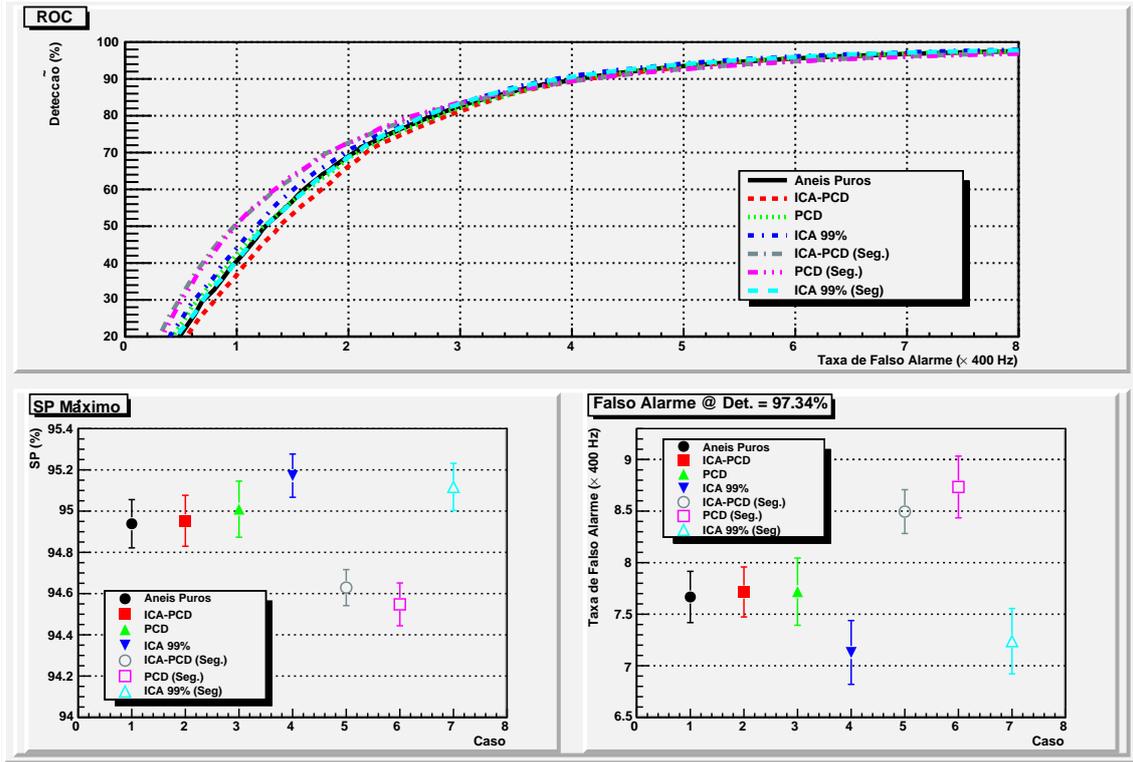


Figura 8.18: Resultados de classificação neural obtidos para a ICA baseada na compactação dos anéis via PCD.

$10 \leq E_T \leq 30$ GeV. Ainda assim, esta abordagem conseguiu prover valores de falso alarme menores que o T2Calo. Em função de η , contudo, a versão baseada em componentes independentes sofreu mais do que as outras abordagens na região do *crack*, porém oferecendo valores bastante superiores ao T2Calo nesta região. Para o falso alarme, mais uma vez, o mesmo permanece mais baixo do que o do T2Calo ao longo de toda a faixa de η .

8.4.3 Compactação por PCD

Conforme dito no começo da Seção 8.4, a motivação para a utilização de componentes principais de discriminação como um pré-processamento a ser realizado antes da extração de componentes independentes é isolar, via PCD, os componentes que melhor distinguem as duas classes de partículas. A ICA será empregada, a partir destes componentes mais relevantes, para efetuar a decorrelação não linear destes, provendo informação independente útil à discriminação.

São apresentados, na Figura 8.18, os resultados obtidos para a abordagem com-

binando PCD e ICA. Para efeitos de comparação, a figura também apresenta os melhores resultados (segmentados e não segmentados) obtidos apenas com PCD, e para a ICA com corte de dimensão via PCA. A ICA compactada por PCD, para o caso não segmentado, possibilitou uma redução de 92% da dimensão do espaço de entrada, e, conseguiu, mesmo assim, oferecer eficiências de classificação equivalentes às obtidas com anéis puros. Adicionalmente, esta abordagem obteve eficiências próximas às obtidas com a ICA compactada por PCA, porém, empregando $\sim 78\%$ menos de informação.

Para o caso segmentado, a extração de componentes independentes após a projeção nos componentes principais de discriminação proporcionou uma pequena melhora em relação a utilização apenas dos componentes principais de discriminação. Entretanto, no que tange a eficiência de classificação, esta melhora não foi suficientemente grande para tornar a abordagem segmentada uma melhor opção do que a sua versão não segmentada.

Para rápida referência, a Tabela 8.4 apresenta os resultados obtidos em cada uma das abordagens realizadas nesta seção. Apresenta-se o SP máximo, a probabilidade de detecção e o falso alarme que proveram o máximo SP, e o falso alarme obtido para uma eficiência de detecção de 97,34%, que é a probabilidade de detecção alcançada pelo T2Calo, para o mesmo conjunto de dados empregado neste capítulo.

8.5 Relevância dos Componentes

As técnicas abordadas para o desenvolvimento do classificador elétron / jato foram eficientes no que tange isolar a informação útil para a classificação, proporcionando a redução do espaço de entrada do sistema de classificação. Por outro lado, uma maior redução no número de componentes pode ser obtida observando-se como cada um deles contribui, isoladamente, para a composição da saída do classificador, permitindo o descarte inteligente de componentes irrelevantes, quando uma maior velocidade de execução é requerida pelo sistema de filtragem. Isto é feito através da análise da relevância [89] de cada uma das entradas aplicadas ao classificador neural. No caso da análise de componentes independentes, a relevância permite, ainda, identificar as fontes realmente relevantes ao discriminador.

Tabela 8.4: Resumo dos resultados obtidos para cada abordagem utilizando classificador neural. O melhor resultado encontrado está em negrito.

Abordagem	Topologia da Rede	SP_{max} (%)	$P_d @ SP_{max}$ (%)	$P_f @ SP_{max}$ ($\times 400$ Hz)	$P_f @ P_d = 97.34\%$ ($\times 400$ Hz)
Anéis Puros	$100 \times 10 \times 1$	94.94 ± 0.12	96.69 ± 0.27	6.79 ± 0.30	7.67 ± 0.25
PCA 99%	$36 \times 10 \times 1$	94.96 ± 0.10	96.75 ± 0.31	6.81 ± 0.35	7.59 ± 0.22
PCA 99% (Seg.)	$49 \times 10 \times 1$	95.15 ± 0.11	96.90 ± 0.34	6.60 ± 0.30	7.21 ± 0.23
PCA 97%	$15 \times 10 \times 1$	94.49 ± 0.09	96.39 ± 0.28	7.39 ± 0.34	8.70 ± 0.17
PCA 97% (Seg.)	$31 \times 10 \times 1$	94.83 ± 0.09	96.78 ± 0.36	7.10 ± 0.31	7.87 ± 0.27
PCA Avg. Root	$10 \times 5 \times 1$	93.91 ± 0.12	95.84 ± 0.29	8.01 ± 0.35	10.32 ± 0.40
PCA Avg. Root (Seg.)	$16 \times 10 \times 1$	94.41 ± 0.09	96.41 ± 0.23	7.57 ± 0.31	8.97 ± 0.16
PCD	$100 \times 8 \times 1$	95.01 ± 0.14	96.67 ± 0.20	6.64 ± 0.24	7.72 ± 0.33
PCD (Seg.)	$19 \times 10 \times 1$	94.55 ± 0.10	96.08 ± 0.27	6.97 ± 0.25	8.73 ± 0.30
ICA 99%	$36 \times 10 \times 1$	95.17 ± 0.10	96.86 ± 0.52	6.50 ± 0.39	7.13 ± 0.31
ICA 99% (Seg.)	$49 \times 10 \times 1$	95.12 ± 0.11	96.92 ± 0.27	6.66 ± 0.19	7.24 ± 0.32
ICA 97%	$15 \times 10 \times 1$	94.68 ± 0.08	96.54 ± 0.42	7.16 ± 0.42	8.18 ± 0.24
ICA 97% (Seg.)	$31 \times 10 \times 1$	95.06 ± 0.09	96.87 ± 0.39	6.72 ± 0.28	7.38 ± 0.27
ICA Avg. Root	$10 \times 5 \times 1$	94.12 ± 0.14	96.18 ± 0.42	7.92 ± 0.41	9.64 ± 0.34
ICA Avg. Root (Seg.)	$16 \times 10 \times 1$	94.45 ± 0.06	96.35 ± 0.31	7.43 ± 0.27	8.78 ± 0.21
ICA-PCD	$8 \times 3 \times 1$	94.95 ± 0.12	96.60 ± 0.20	6.67 ± 0.22	7.72 ± 0.24
ICA-PCD (Seg.)	$19 \times 10 \times 1$	94.63 ± 0.09	96.31 ± 0.39	7.03 ± 0.34	8.50 ± 0.21

A relevância R_i da i -ésima entrada fornecida a um classificador é dada por

$$R_i^{MSE} = \frac{1}{N} \sum_{j=1}^N [o(\mathbf{x}_j) - o(\mathbf{x}_j |_{x_{j,i}=\bar{x}_i})]^2 \quad (8.2)$$

onde N é o número de eventos aplicados ao classificador, e $o(\mathbf{x})$ é a saída produzida pelo classificador, para um dado vetor de entradas \mathbf{x} . Ou seja, a relevância analisa o erro médio quadrático produzido quando a i -ésima entrada é substituída pela sua média.

O produto SP também pode ser empregado para a análise da relevância. Neste caso, a relevância da i -ésima entrada será dada por

$$R_i^{SP} = SP(\mathbf{x}) - SP(\mathbf{x} |_{x_i=\bar{x}_i}) \quad (8.3)$$

Enquanto a equação 8.2 analisa apenas o desvio na saída do classificador, a equação 8.3 observa o desvio no potencial de discriminação. Desta forma, a análise da relevância será realizada, nesta seção, utilizando-se a equação 8.3.

A Figura 8.19 apresenta, para a abordagem sem nenhuma mudança de base, as relevâncias de cada anel. Observa-se que as camadas mais relevantes são o *pré-*

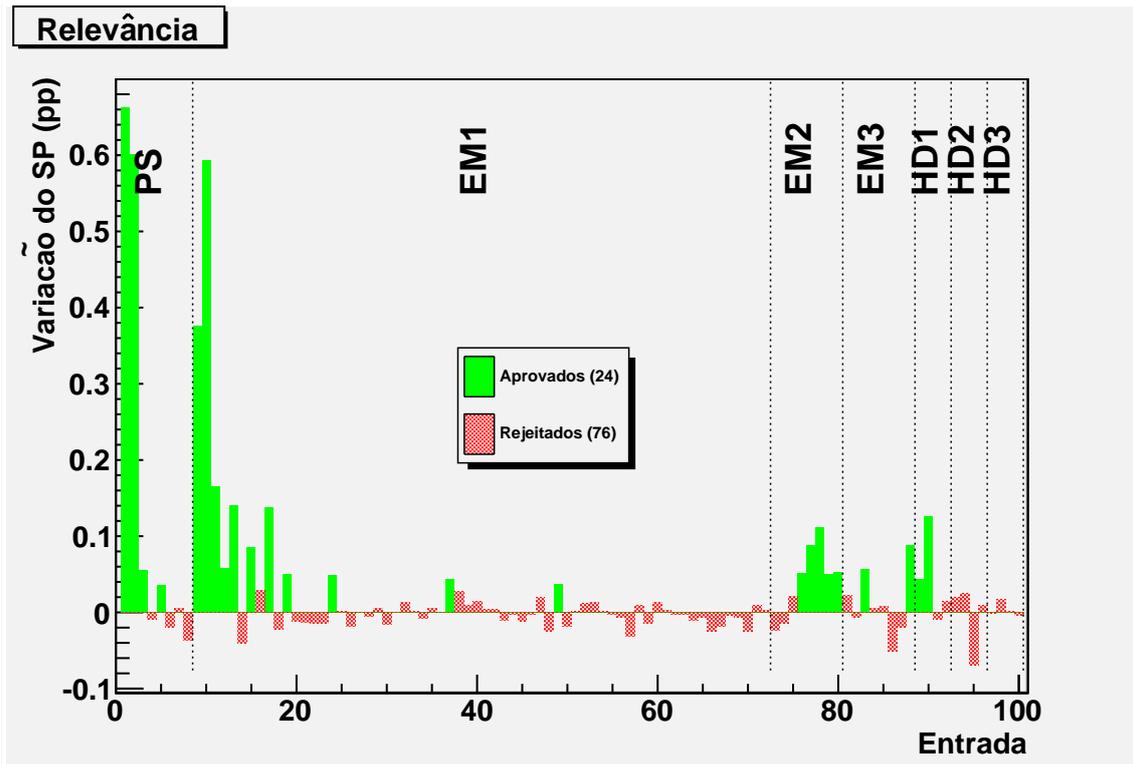
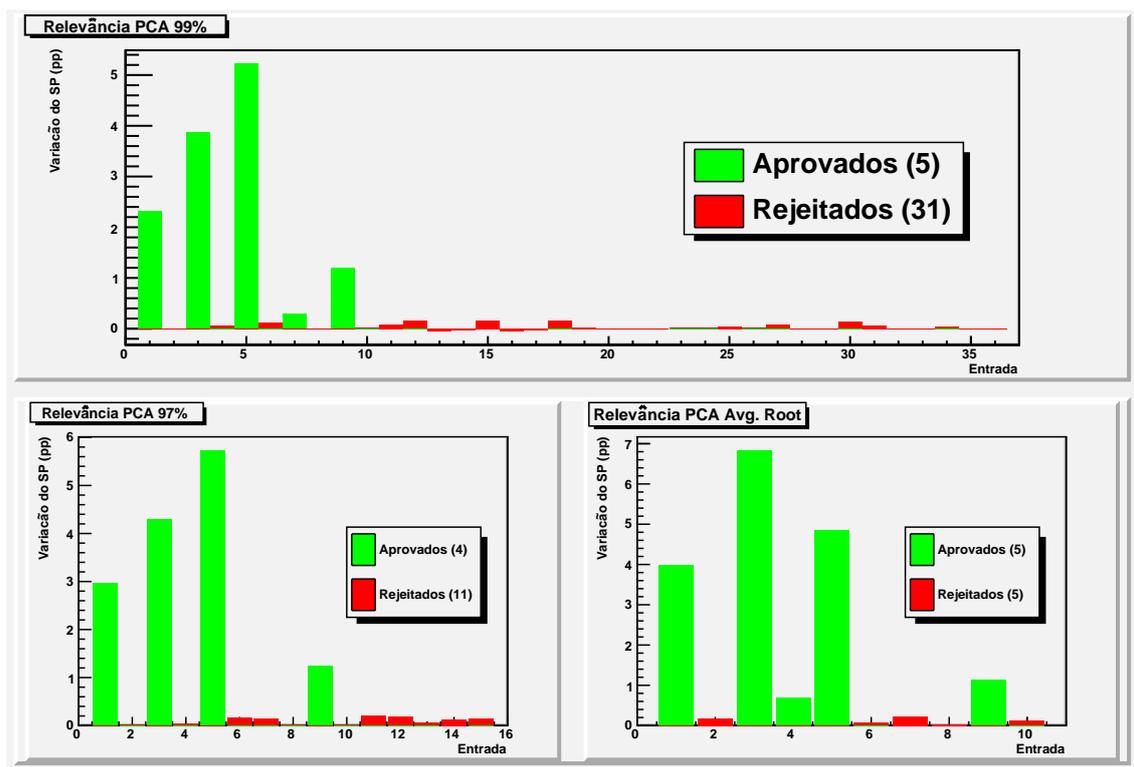


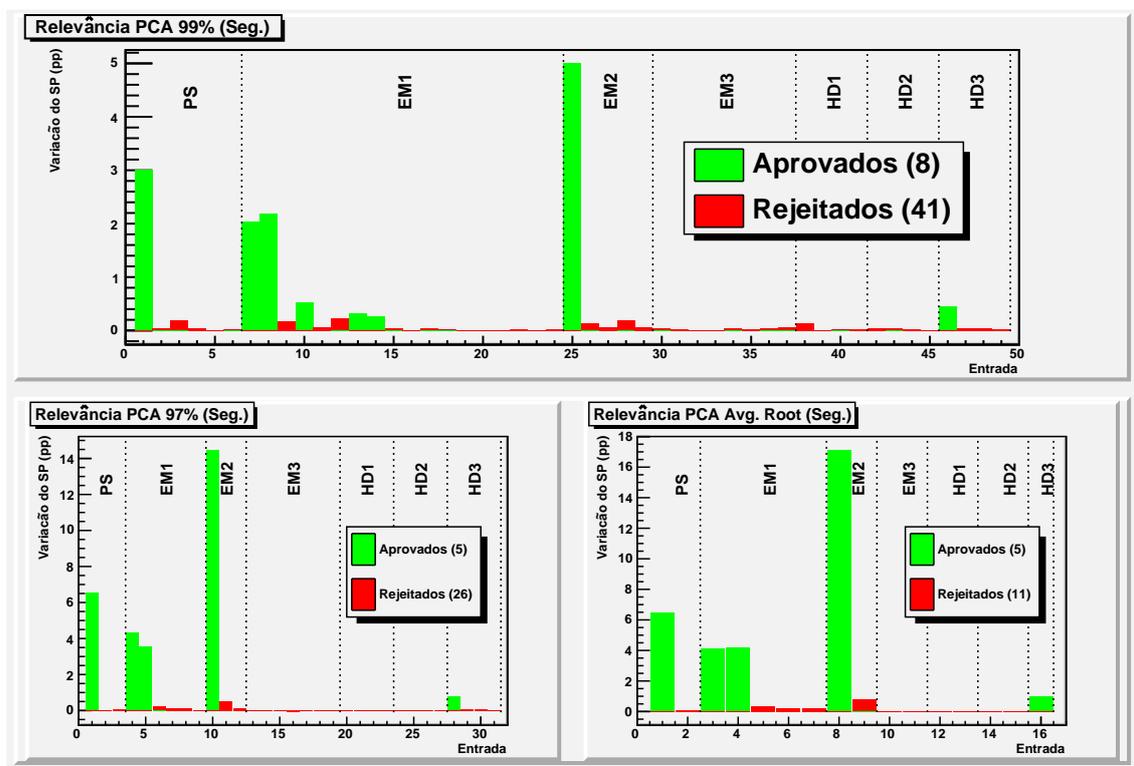
Figura 8.19: Relevância de cada anel topológico para o discriminador neural.

sampler e a EM1. Percebe-se, também, que a relevância destacou os anéis mais externos da EM2, e rejeitou os anéis mais centrais tal como seria esperado pela física de desenvolvimento do chuveiro. Os anéis das camadas hadrônicas foram quase todos rejeitados pela análise da relevância, o que é esperado, uma vez que eventos passíveis de serem distinguíveis através do vazamento de energia para a seção hadrônica já foram eliminados pelo L1, através de seu corte com isolamento. Por fim, a análise da relevância mostra que aproximadamente 30% dos anéis, não só não são relevantes, como inclusive, contribuem negativamente para a eficiência de detecção.

Já na Figura 8.20, apresentam-se as relevâncias das componentes principais. Para o caso não segmentado (Figura 8.20a), observa-se que os componentes mais relevantes não são, necessariamente os primeiros, visto o foco da PCA ser na representação dos dados, e não na distinção entre classes. Para o caso segmentado (Figura 8.20a), novamente observa-se a maior relevância concentrada nas 3 primeiras camadas eletromagnéticas. No caso das camadas hadrônicas, sabe-se que as mesmas possuem muito mais ruído do que sinal. A relevância, mais uma vez, corroborou esta idéia. Entretanto, a informação discriminante contida nestas camadas poderia ser



(a) Não Segmentado



(b) Segmentado

Figura 8.20: Relevância dos componentes principais para o discriminador neural.

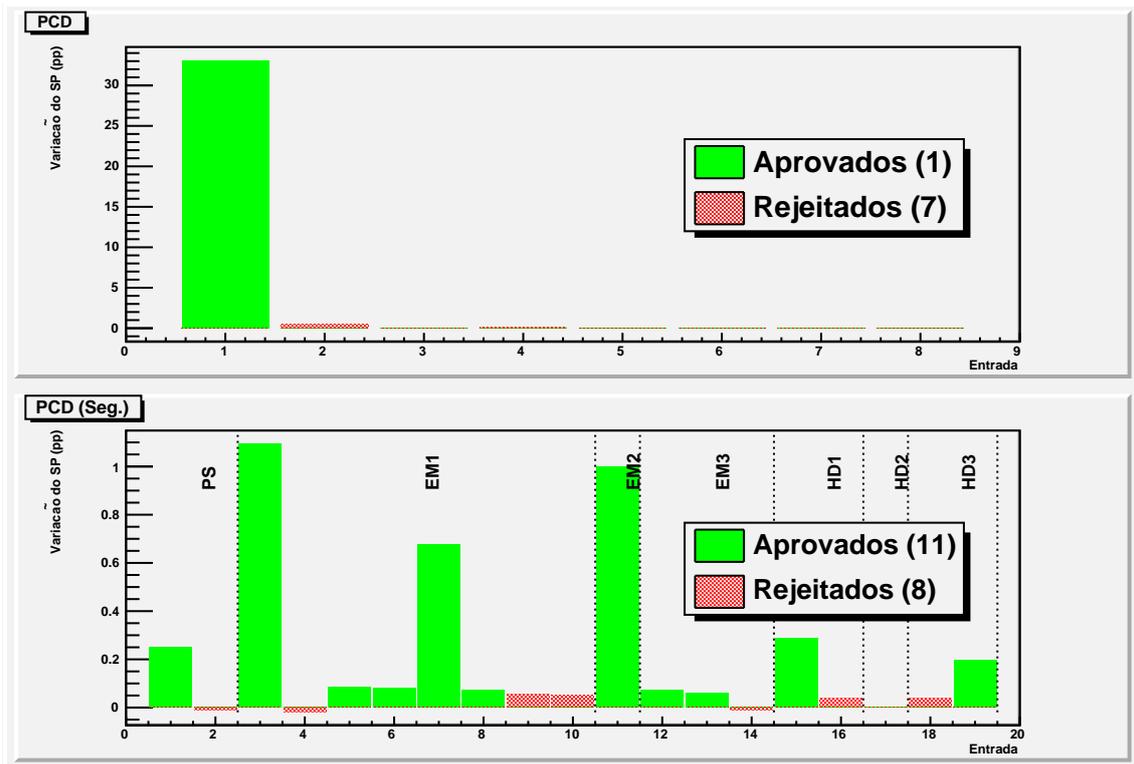


Figura 8.21: Relevância dos componentes principais de discriminação para o discriminador neural. Abordagem não segmentada (em cima) e segmentada (embaixo).

melhor evidenciada através de normalizações mais inteligentes, tais como a normalização sequencial. Em ambos os casos (segmentado e não segmentado), percebe-se que os componentes selecionados em cada corte em energia são aproximadamente os mesmos, e mostram, para o caso não segmentado, por exemplo, que para qualquer corte, praticamente toda a informação relevante está contida nos primeiros 10 componentes.

Em seguida, são apresentadas, na Figura 8.21 as relevâncias dos anéis, após projeção em seus componentes principais de discriminação. Como esperado, a análise da relevância sempre coloca o primeiro componente como o mais relevante. A análise para este método de pré-processamento mostrou que o primeiro componente principal de discriminação obtido para o caso não segmentado é o único que realmente importa para a classificação. Com isso, a classificação baseada neste componente seria feita aplicando-se um corte linear diretamente neste componente, sem a necessidade de uma unidade discriminadora própria.

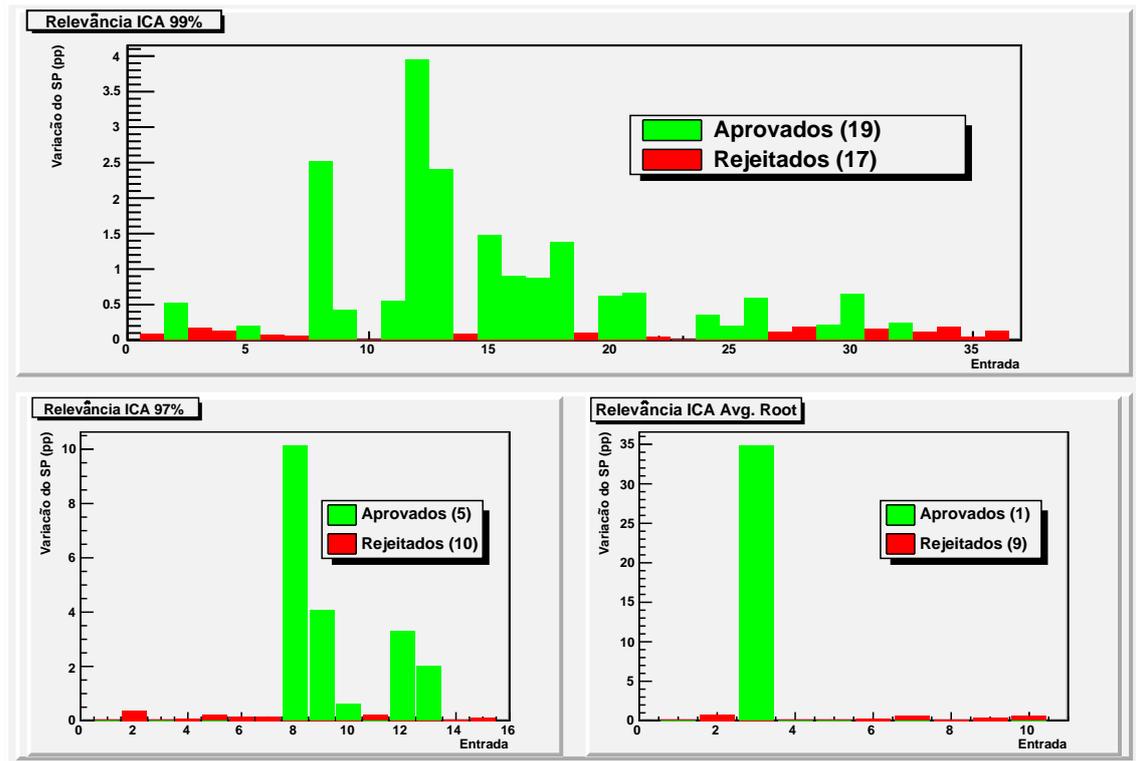
A análise da relevância aplicada aos componentes independentes extraídos, é apresentada na Figura 8.22. No caso da extração segmentada, após compactação

à 99% da energia via PCA, o aparentemente excessivo número de fontes relevantes selecionadas para a EM1 indicam que, pelo menos para esta camada, a extração das fontes independentes pode ter sido distorcida pelo excesso de sensores. Para as situações onde o corte, em energia, foi mais intenso, resultados mais plausíveis são obtidos para a EM1. Mais uma vez, destaca-se a baixa relevância obtida para os componentes provenientes das camadas hadrônicas. Tal como a PCD, a análise da relevância para as fontes independentes extraídas após redução da dimensão via *Average Root* também indicou que apenas um componente é suficiente, bastando-se aplicar um corte linear nos valores obtidos para este componente para a realização da discriminação.

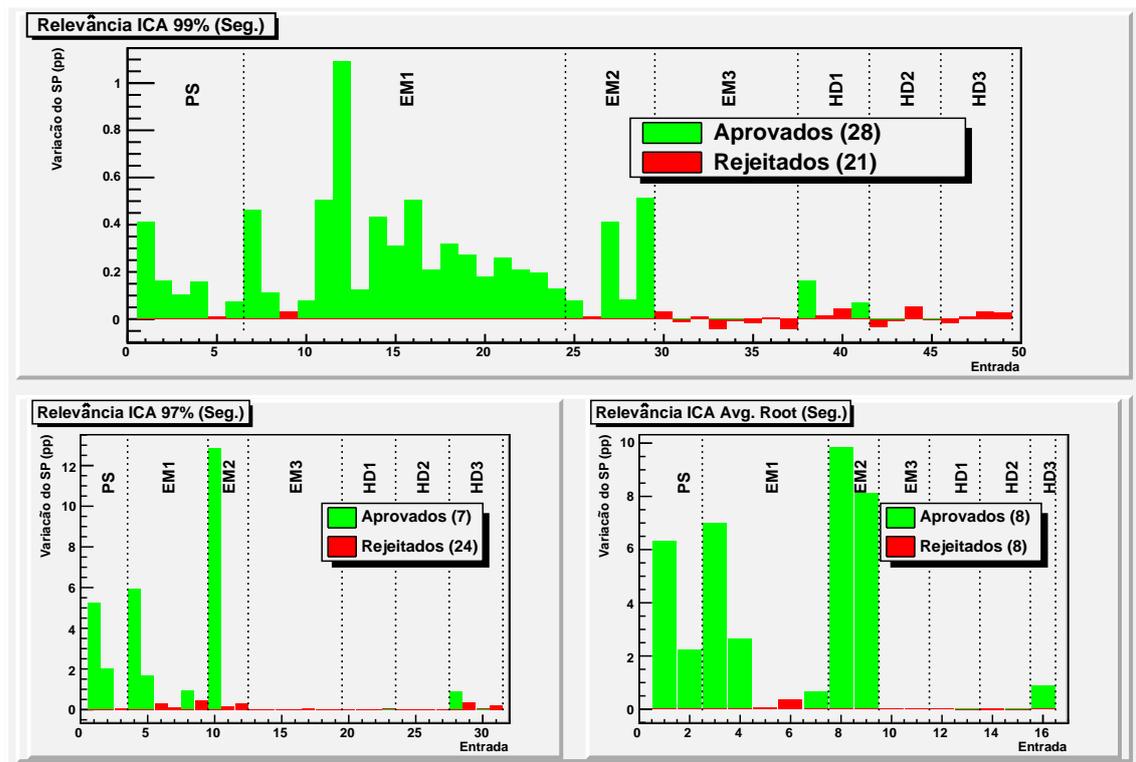
Ao empregar-se a análise da relevância nos componentes independentes extraídos após projeção na base de componentes principais de discriminação, obtém-se o resultado apresentado na Figura 8.23. Nesta abordagem, uma vez que a ICA foi aplicada após a projeção nos componentes principais de discriminação, e que a mesma não garante a ordem dos componentes, percebe-se uma desordem entre os componentes selecionados como relevantes.

Após a análise da relevância, e do corte de variáveis adotado, As redes classificadores foram retreinadas, alimentadas apenas com os componentes selecionados pela análise da relevância. A Tabela 8.5 apresenta, de maneira resumida, os resultados obtidos com o classificador alimentado com as entradas mais relevantes. A Figura 8.24 apresenta o resultado comparando a eficiência de classificação para as entradas mais relevantes obtidas quando os anéis são empregados sem nenhum pré-processamento adicional. Nota-se que a relevância provocou uma pequena perda de eficiência em relação à versão empregando a informação completa.

Para eventos previamente compactados via PCA, na abordagem não segmentada (Figura 8.25a), nota-se que, conforme o corte em energia aumenta, a eficiência da rede alimentada com a informação não compactada pela relevância, tende a se degradar. Entretanto, a análise da relevância selecionou praticamente os mesmos números de componentes nos 3 cortes em energia abordados. A PCA com critério de corte via *Average Root* ficou apenas 0,6 ponto percentual abaixo da sua versão onde nenhum corte por relevância foi adotado. Ainda assim, a relevância permitiu reduzir o número de componentes, para este caso, em 50%. Para o caso segmentado (Fi-



(a) Não Segmentado



(b) Segmentado

Figura 8.22: Relevância dos componentes independentes para o discriminador neural.

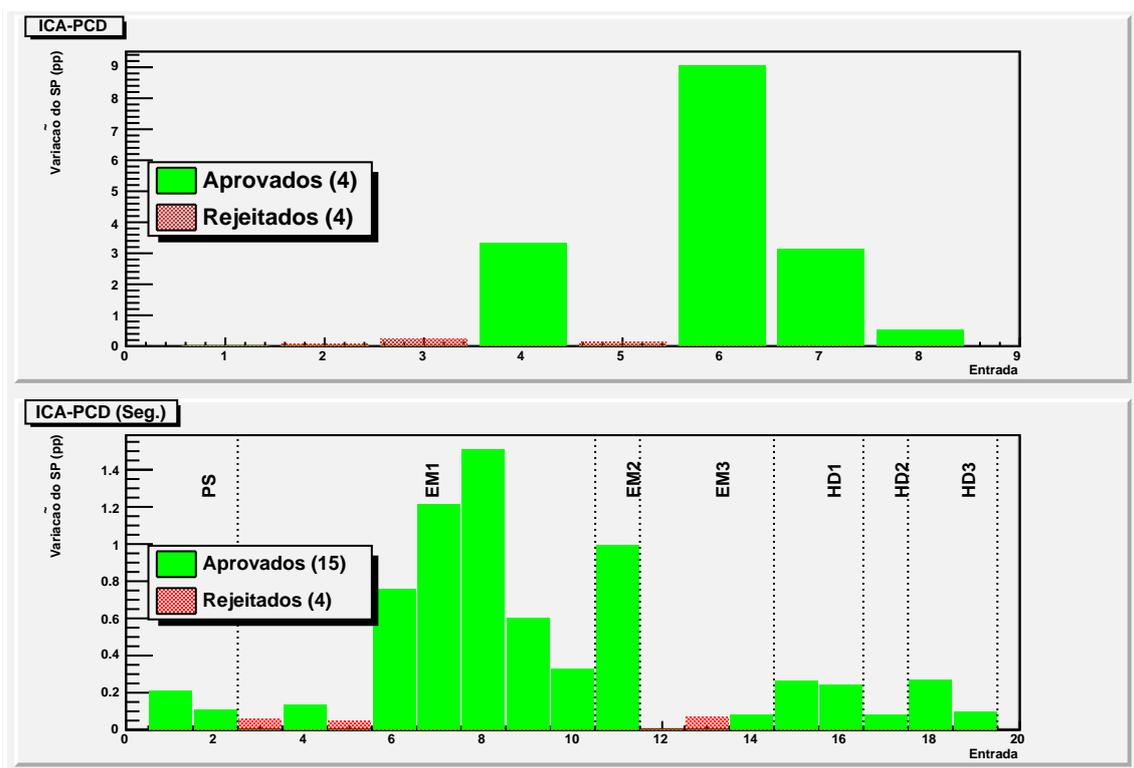


Figura 8.23: Relevância dos componentes independentes selecionados por componentes principais de discriminação. Não segmentada (em cima) e segmentada (embaixo)

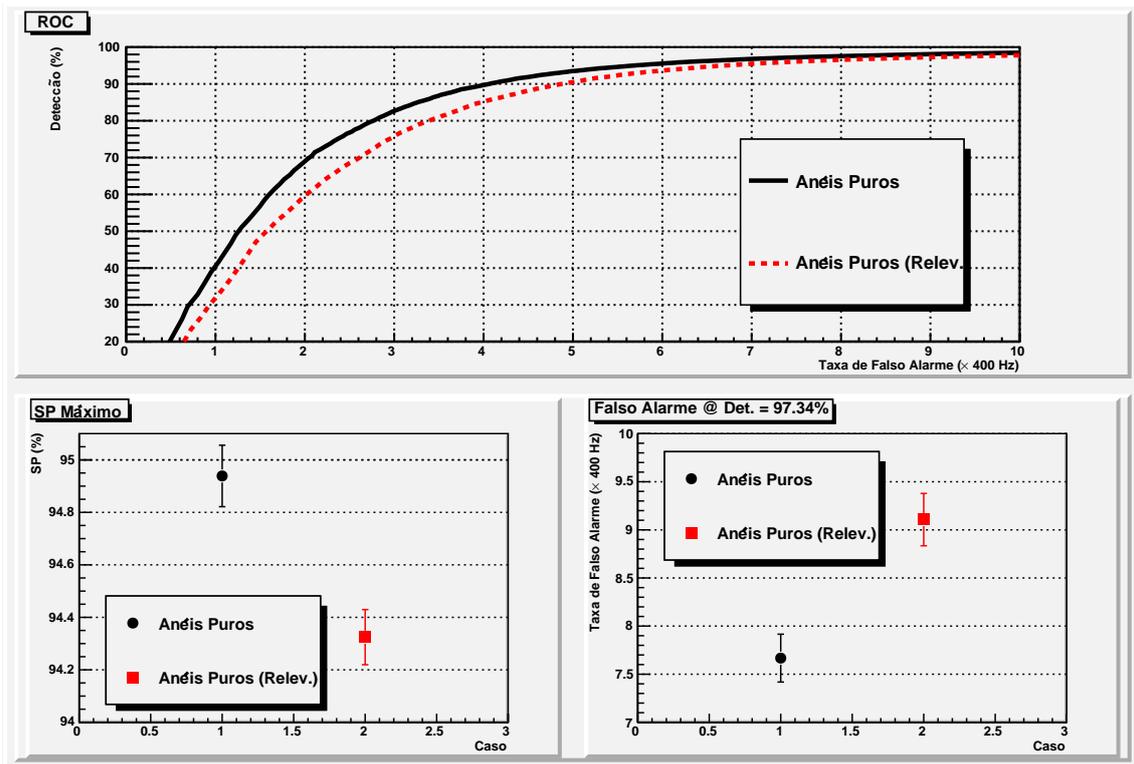
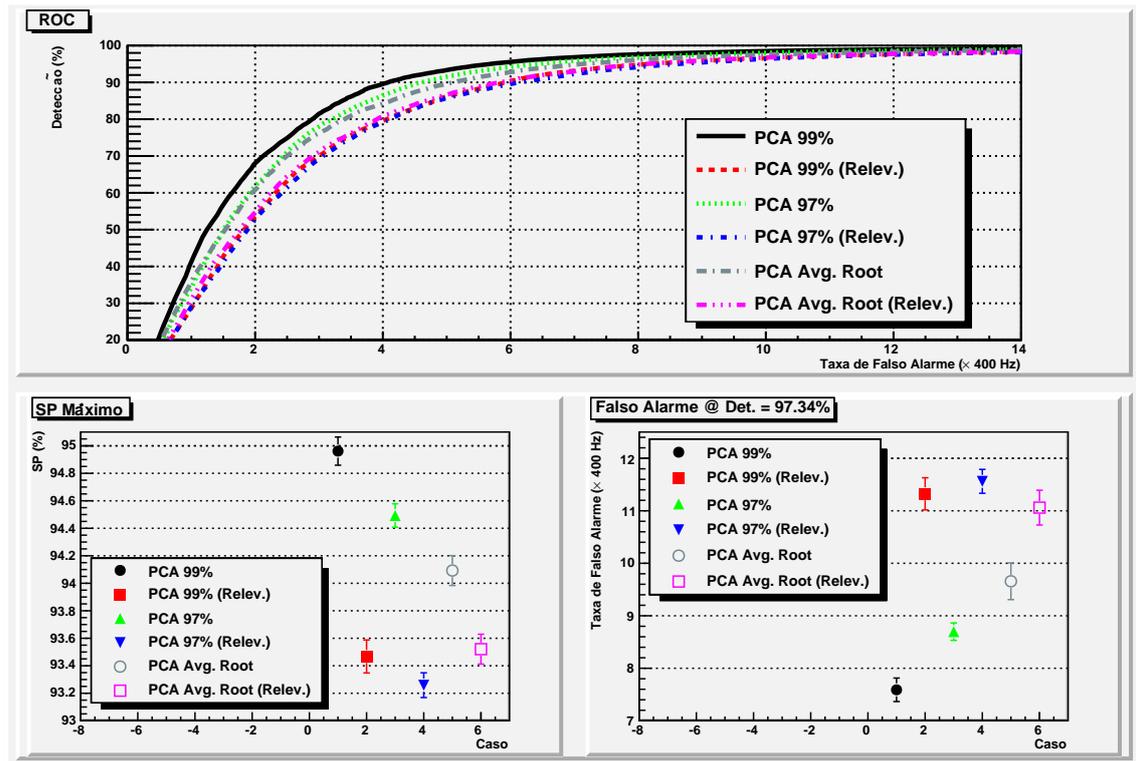


Figura 8.24: Resultados de classificação para as entradas mais relevantes obtidas com anéis puros.

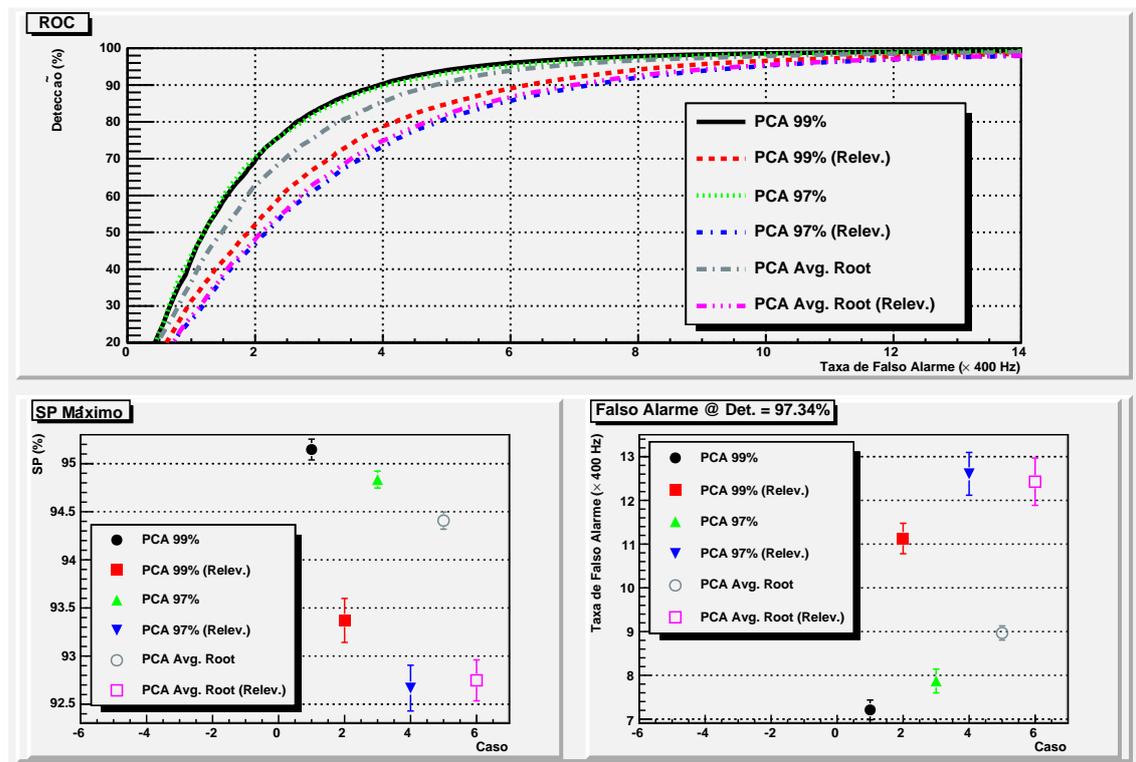
gura 8.25b), também nota-se uma pequena degradação na eficiência de classificação, ao passo que a redução do número de componentes apresentados ao classificador foi reduzido, via relevância, em pelo menos 50%. No caso particular da PCA com corte em 97% da energia, e com corte via *Average Root*, os resultados obtidos ficaram estatisticamente empatados, o que é coerente, visto que ambos os métodos selecionaram os mesmos componentes através da análise da relevância,

A análise RICA, com compactação em energia via PCA é apresentada na Figura 8.26. Nota-se que um corte menos intenso favorece a análise de componentes independentes relevantes. A análise segmentada, apresentada na Figura 8.26b, por conter mais detalhes sobre o sinal, oferece melhores resultados para o RICA. No caso da abordagem não segmentada (Figura 8.26a), observa-se que apenas um único componente foi selecionado para o caso onde o corte por energia foi feito pelo critério *Average Root*. Desta forma, a aplicação de um limiar de corte no valor desta variável é suficiente para a classificação.

Na análise da eficiência de classificação obtida ao se aplicar o corte por relevância dos componentes inicialmente compactados por PCD, nota-se que a PCD não seg-

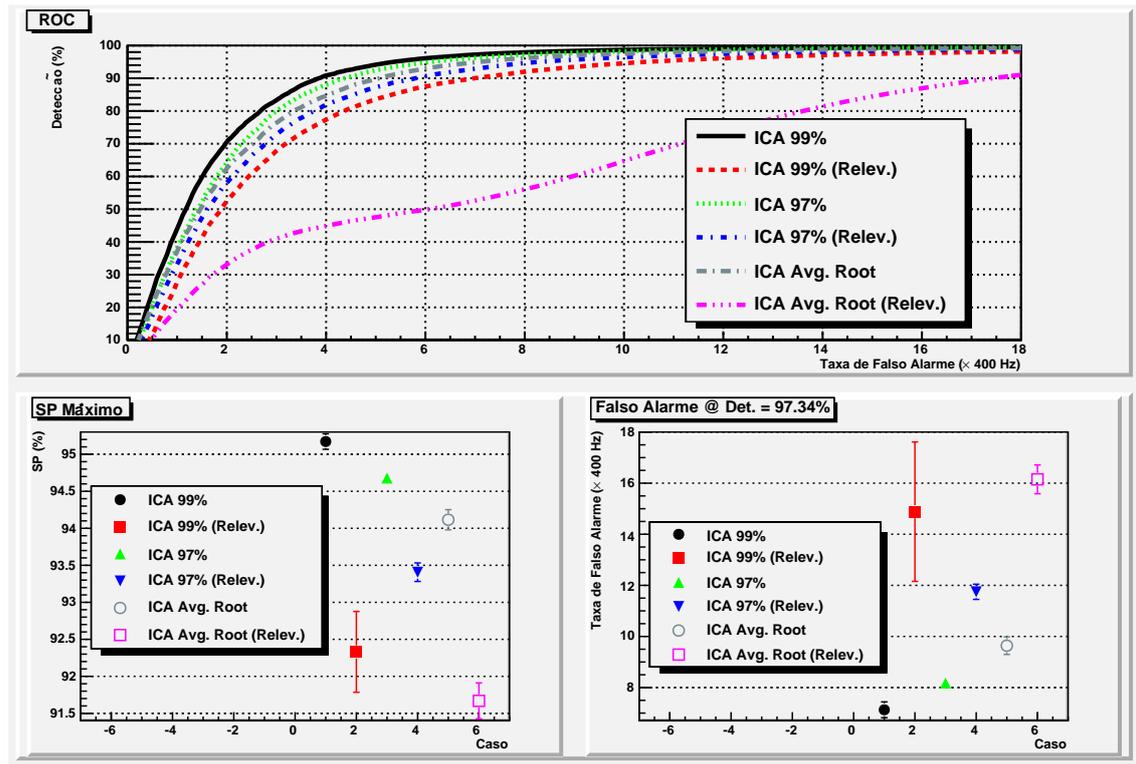


(a) Não Segmentado

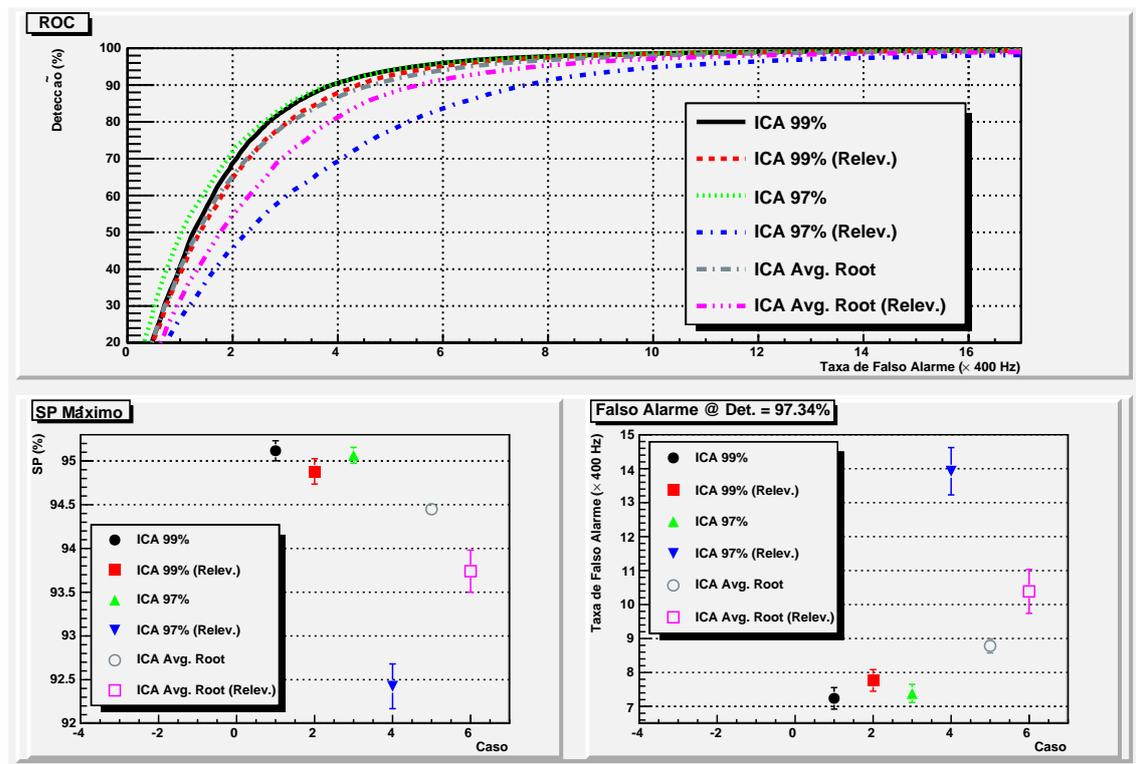


(b) Segmentado

Figura 8.25: Resultados de classificação para as entradas mais relevantes obtidas com os pré-processamentos com compactação por PCA.



(a) Não Segmentado



(b) Segmentado

Figura 8.26: Resultados de classificação para as entradas mais relevantes obtidas com ICA compactada por PCA.

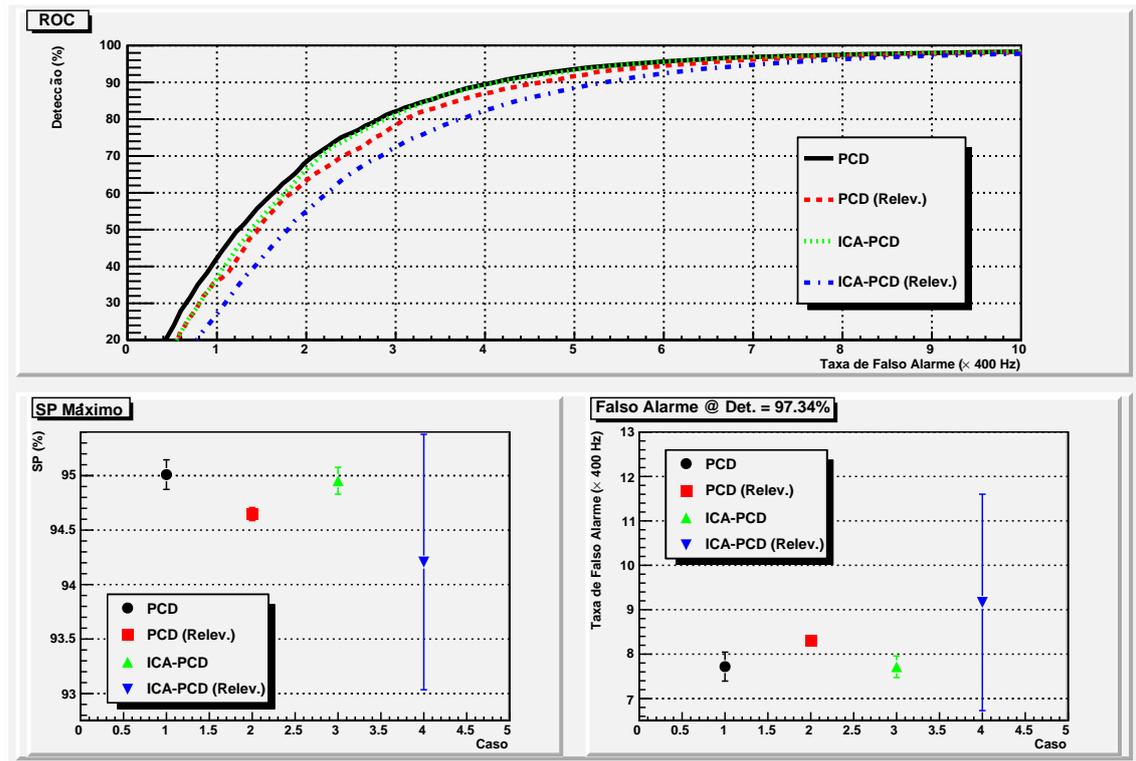
Tabela 8.5: Resumo dos resultados obtidos para cada abordagem utilizando redes neurais alimentadas com as entradas mais relevantes. O melhor resultado encontrado está em negrito.

Abordagem	Topologia da Rede	SP_{max} (%)	$P_d @ SP_{max}$ (%)	$P_f @ SP_{max}$ ($\times 400$ Hz)	$P_f @ P_d = 97.34\%$ ($\times 400$ Hz)
Anéis Puros	$24 \times 10 \times 1$	94.32 ± 0.11	96.26 ± 0.29	7.59 ± 0.39	9.11 ± 0.27
PCA 99%	$5 \times 3 \times 1$	93.47 ± 0.12	95.51 ± 0.35	8.55 ± 0.35	11.32 ± 0.31
PCA 99% (Seg.)	$8 \times 3 \times 1$	93.37 ± 0.23	95.87 ± 0.31	9.09 ± 0.44	11.13 ± 0.35
PCA 97%	$4 \times 3 \times 1$	93.26 ± 0.09	95.60 ± 0.52	9.05 ± 0.56	11.56 ± 0.23
PCA 97% (Seg.)	$5 \times 3 \times 1$	92.67 ± 0.24	95.73 ± 0.40	10.34 ± 0.53	12.61 ± 0.49
PCA Avg. Root	$5 \times 3 \times 1$	93.52 ± 0.11	95.68 ± 0.50	8.61 ± 0.47	11.06 ± 0.33
PCA Avg. Root (Seg.)	$5 \times 3 \times 1$	92.75 ± 0.21	95.43 ± 0.43	9.90 ± 0.51	12.43 ± 0.54
PCD	1×1	94.65 ± 0.06	96.88 ± 0.11	7.56 ± 0.15	8.31 ± 0.15
PCD (Seg.)	$11 \times 5 \times 1$	94.29 ± 0.11	95.96 ± 0.26	7.37 ± 0.36	9.31 ± 0.29
ICA 99%	$19 \times 10 \times 1$	92.33 ± 0.55	94.53 ± 1.01	9.84 ± 0.68	14.88 ± 2.73
ICA 99% (Seg.)	$28 \times 10 \times 1$	94.88 ± 0.15	96.81 ± 0.25	7.03 ± 0.26	7.77 ± 0.32
ICA 97%	$5 \times 3 \times 1$	93.41 ± 0.13	95.23 ± 0.25	8.40 ± 0.31	11.75 ± 0.30
ICA 97% (Seg.)	$7 \times 3 \times 1$	92.42 ± 0.26	95.03 ± 0.27	10.14 ± 0.52	13.93 ± 0.70
ICA Avg. Root	1×1	91.67 ± 0.24	94.16 ± 0.43	10.79 ± 0.52	16.15 ± 0.56
ICA Avg. Root (Seg.)	$8 \times 3 \times 1$	93.74 ± 0.24	96.10 ± 0.46	8.59 ± 0.49	10.39 ± 0.65
ICA-PCD	$4 \times 3 \times 1$	94.21 ± 1.17	96.62 ± 0.51	8.17 ± 1.99	9.16 ± 2.44
ICA-PCD (Seg.)	$15 \times 5 \times 1$	94.16 ± 0.29	96.10 ± 0.41	7.77 ± 0.66	9.53 ± 0.76

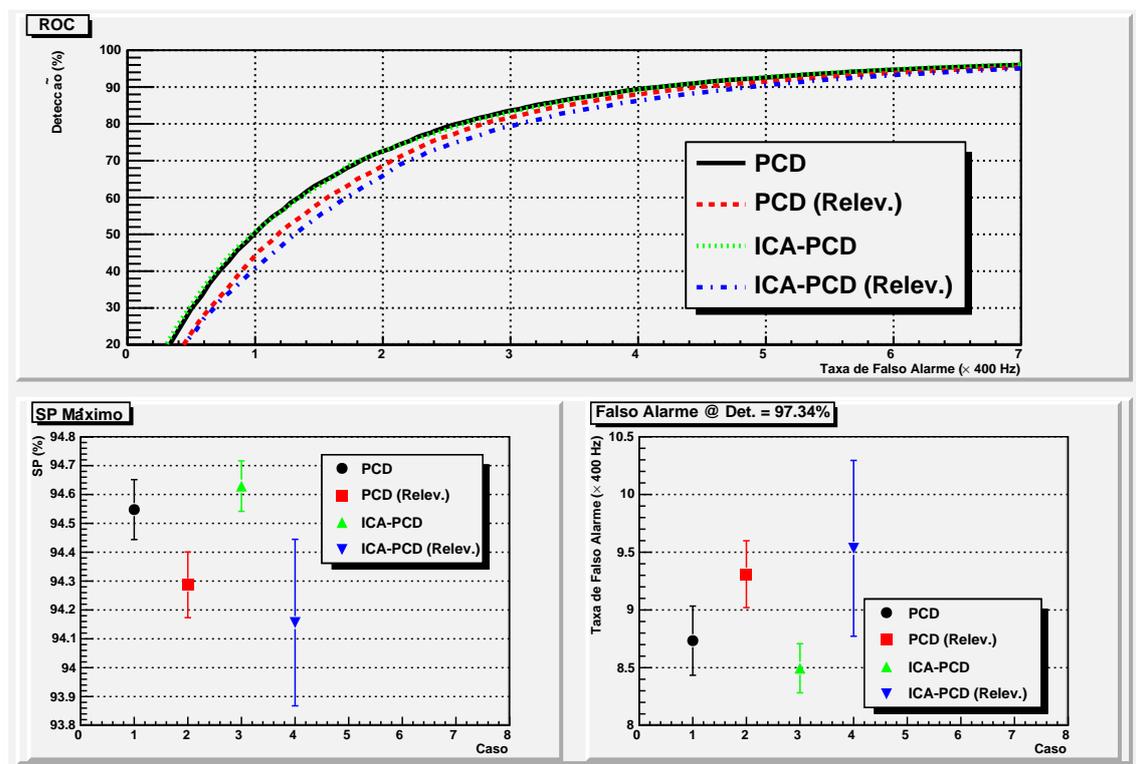
mentada (vide Figura 8.27a) oferece bons resultados, mesmo empregando um único componente, o que mostra que a aplicação de um limiar de corte ao valor obtido com a projeção neste componente é suficiente para se implementar a etapa de classificação. Para o caso segmentado, apresentado na Figura 8.27b, observa-se que a faixa dinâmica na qual os resultados obtidos estão contidos é muito estreita, o que mostra que o corte de componentes por análise da relevância permitiu sustentar em todos os casos, eficiências de detecção muito próximas às obtidas quando nenhum componente é descartado por relevância.

8.6 Resultados com Classificadores Lineares

As técnicas apresentadas neste capítulo, por tornarem a informação relevante para a classificação mais acessível, podem simplificar de tal forma a tarefa de classificação ao ponto de um classificador linear ser suficiente para realizar, satisfatoriamente, a distinção entre elétrons e jatos. Desta forma, as técnicas de pré-processamento



(a) Não Segmentado



(b) Segmentado

Figura 8.27: Resultados de classificação para as entradas mais relevantes obtidas com os pré-processamentos com compactação por PCD.

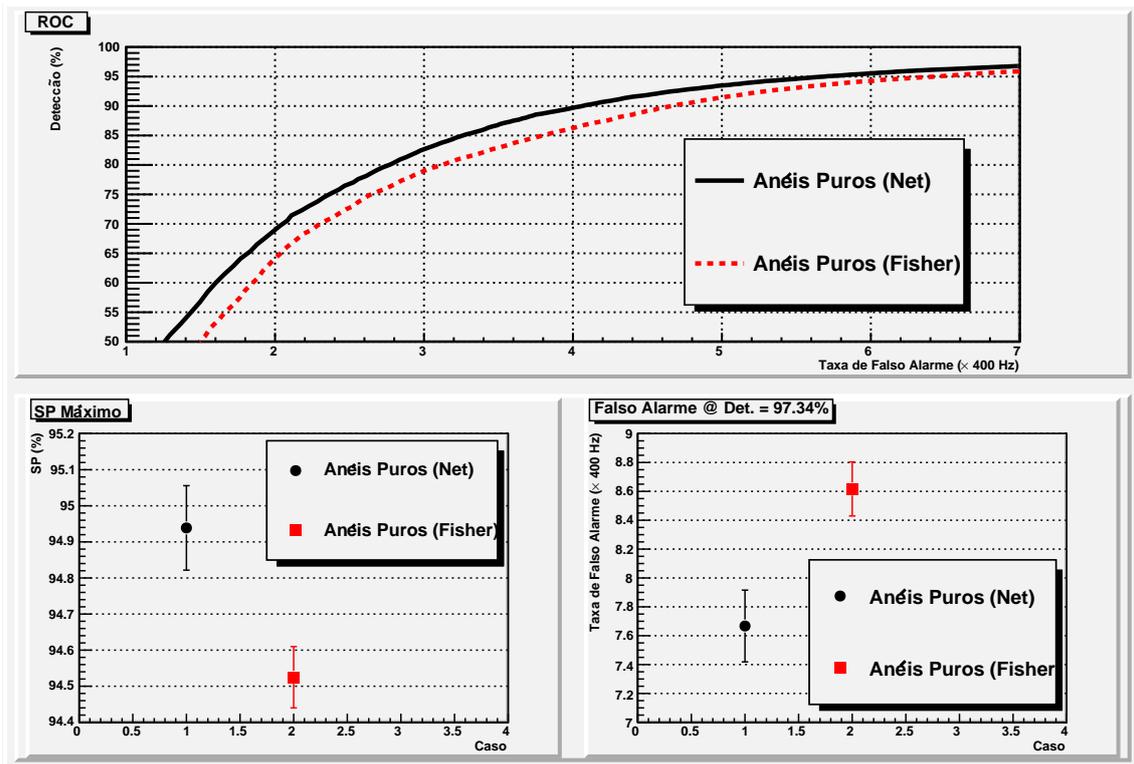
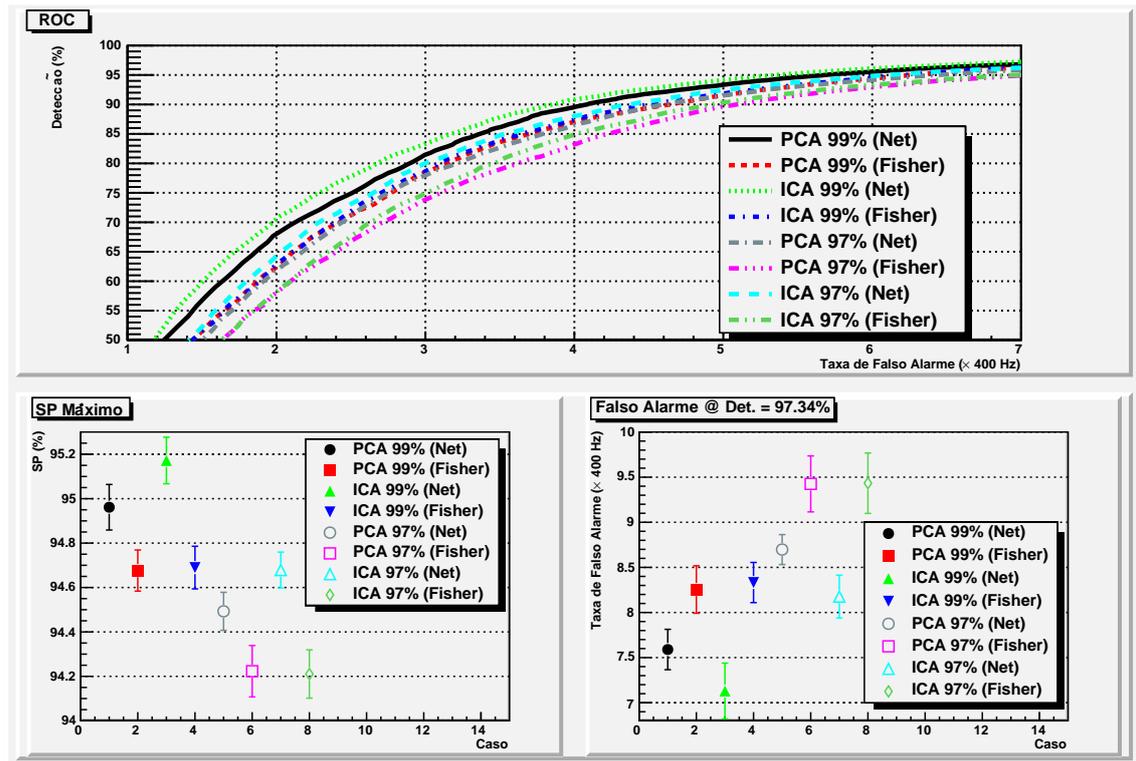


Figura 8.28: Comparação entre rede neural e discriminante de Fisher para anéis puros.

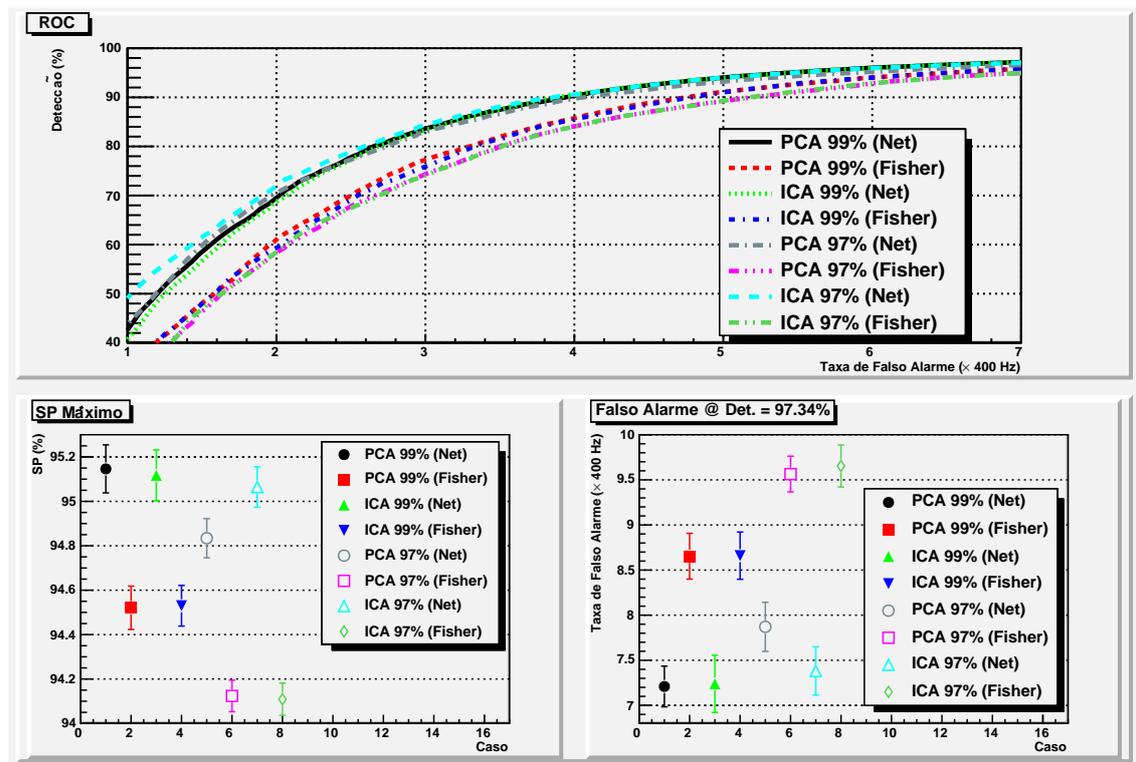
discutidas neste capítulo foram utilizadas para desenvolver um discriminador de Fisher [90].

É apresentado, na Figura 8.28, os resultados de classificação utilizando o discriminador de Fisher alimentado apenas com os anéis, sem nenhum pré-processamento adicional. Observa-se que o classificador não linear apresenta melhores resultados, mostrando que o problema é, de fato, não linear. Entretanto, a diferença entre os resultados obtidos com o classificador linear e não linear não é grande (menos de 1 ponto percentual de queda para o falso alarme, para uma detecção de 97,34%), mostrando que a classificação linear pode ser cogitada caso se deseje maior velocidade de execução, em detrimento de uma pequena queda na eficiência de classificação.

A Figura 8.29 apresenta os resultados ao comparar-se a classificação através de redes neurais e por Fisher para os casos onde a dimensão do sinal foi compactada via PCA (abordagem segmentada e não segmentada). Também são apresentados os resultados obtidos com os componentes independentes extraídos após a compactação da base original por PCA. Tal como nos casos sem compactação da base, todas as abordagens obtiveram melhores resultados com o classificador não linear.



(a) Não Segmentado



(b) Segmentado

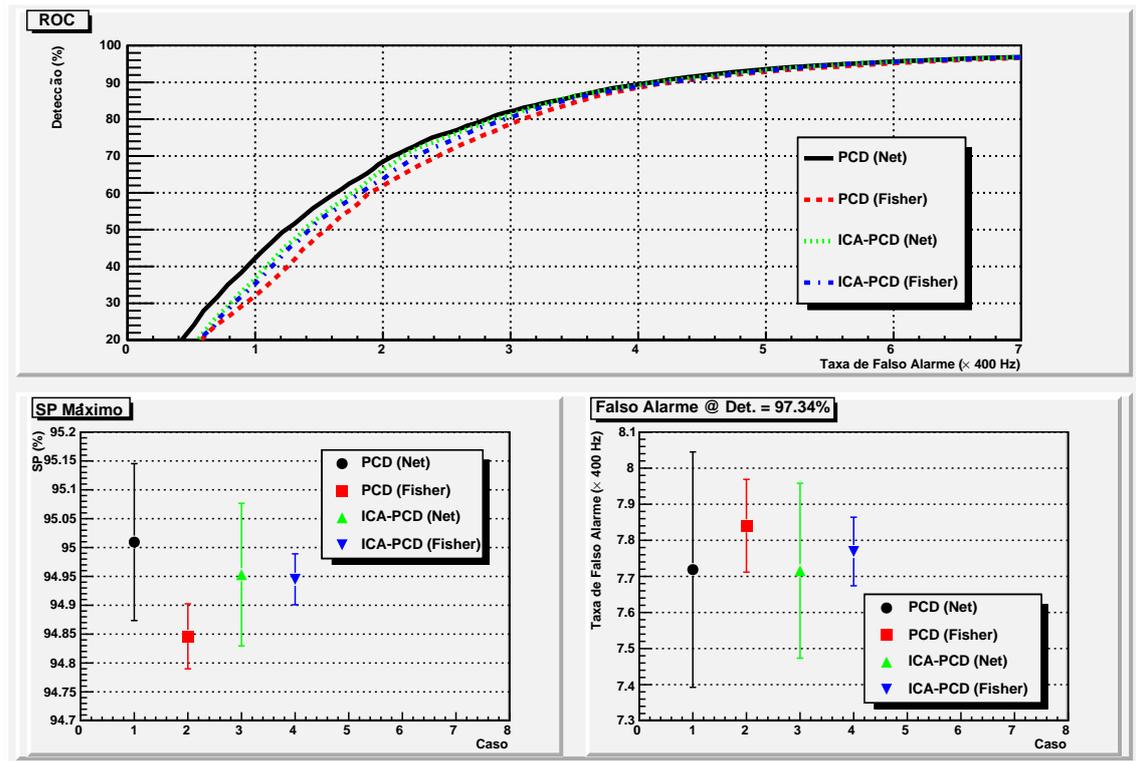
Figura 8.29: Comparação entre rede neural e discriminante de Fisher para casos com compactação via PCA.

Entretanto, mais uma vez a diferença entre os classificadores lineares e seus correspondentes não lineares foi pequena. Por fim, observa-se que a diferença entre a versão neural e o Fisher tende a ser menor quanto menor for a intensidade do corte de componentes pelo pré-processamento.

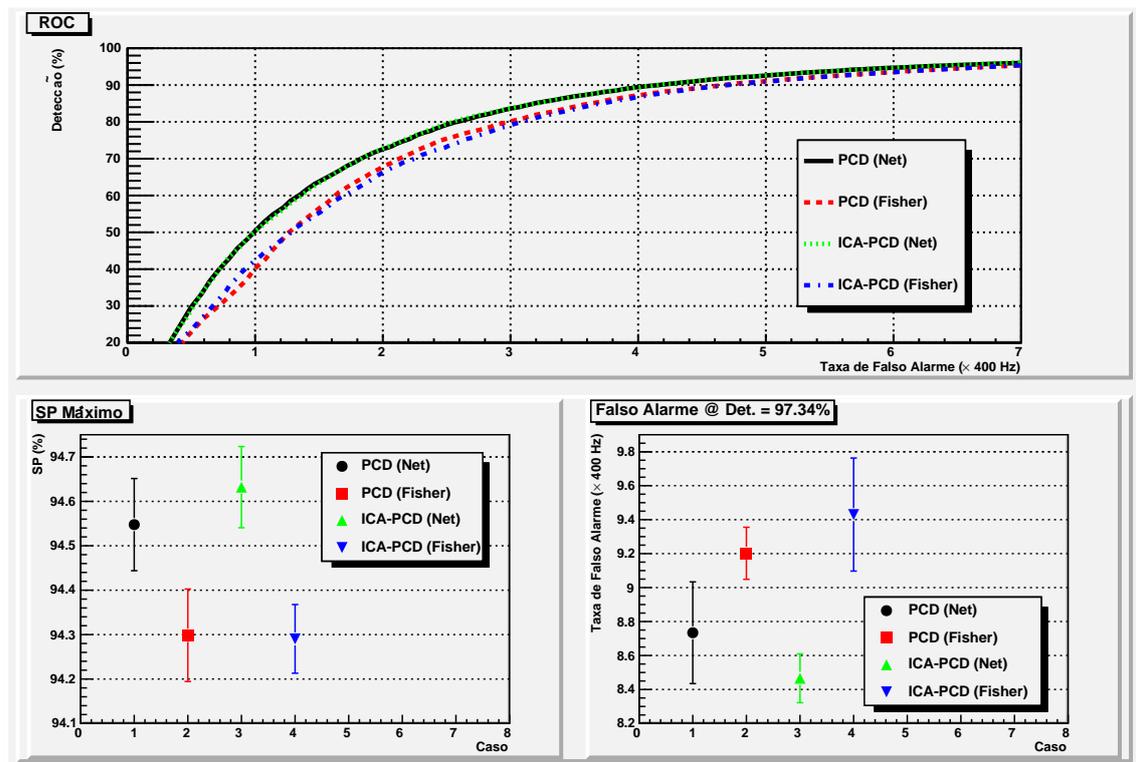
Observando-se a Figura 8.29, nota-se que os resultados obtidos com discriminadores de Fisher para PCA e ICA estão sempre empatados. A razão de tal motivo é que a diferença entre PCA e ICA reside no fato da PCA só descorrelacionar os 2 primeiros momentos, ao passo que a ICA descorrelaciona, além destes, os momentos superiores. Entretanto, o discriminador de Fisher só observa os 2 primeiros momentos, não sendo capaz de se beneficiar da descorrelação não linear promovida pela ICA.

Os resultados obtidos, ao se aplicar um classificador linear sobre os dados inicialmente compactados por PCD, estão apresentados na Figura 8.30. As abordagens não segmentadas (Figura 8.30a) caso não segmentado, no geral, são as que menos perdem, em eficiência de classificação, ao alimentar um discriminador linear. No caso não segmentado, as diferenças são quase desprezíveis. Esta baixa perda oriunda-se do fato da PCD já projetar os sinais de entrada em uma base não linear, de forma que aplicar um corte linear em uma base não linear, é equivalente a aplicar um corte não linear na base original dos eventos. A descorrelação não linear proporcionada pela ICA, após a projeção nos PCD, permitiu uma ligeira melhora, indicando que, e uma base não linear, o discriminante de Fisher foi capaz de se beneficiar da descorrelação dos momentos de ordem superior proporcionada pela ICA. Para o caso segmentado, (Figura 8.30b), a utilização de um discriminador linear provocou um queda superior, na eficiência, do que a versão não segmentada.

A Tabela 8.6 apresenta, de forma resumida, os resultados obtidos, em cada abordagem, ao adotar-se um discriminador linear para a etapa de classificação. Para uma mesma probabilidade de detecção (97,34%), o melhor resultado foi obtido com a projeção nos componentes principais de discriminação, resultando num falso alarme de 7,84%. O pior resultado (10,57%) foi obtido com a projeção (não segmentada) em componentes principais selecionados pelo critério de *Average Root*. Entretanto, mesmo o pior resultado, representa, para a mesma probabilidade de detecção, uma redução de $\sim 48\%$ em relação ao falso alarme obtido com o T2Calo.



(a) Não Segmentado



(b) Segmentado

Figura 8.30: Comparação entre rede neural e discriminante de Fisher para casos com compactação via PCD.

Tabela 8.6: Resumo dos resultados obtidos para cada abordagem utilizando discriminador de Fisher. O melhor resultado encontrado está em negrito.

Abordagem	Topologia da Rede	SP_{max} (%)	$P_d @ SP_{max}$ (%)	$P_f @ SP_{max}$ ($\times 400$ Hz)	$P_f @ P_d = 97.34\%$ ($\times 400$ Hz)
Anéis Puros	100×1	94.52 ± 0.08	96.41 ± 0.37	7.34 ± 0.41	8.62 ± 0.19
PCA 99%	36×1	94.68 ± 0.09	96.49 ± 0.29	7.12 ± 0.24	8.25 ± 0.26
PCA 99% (Seg.)	49×1	94.52 ± 0.10	96.53 ± 0.18	7.47 ± 0.08	8.65 ± 0.25
PCA 97%	15×1	94.22 ± 0.12	96.26 ± 0.31	7.79 ± 0.14	9.43 ± 0.31
PCA 97% (Seg.)	31×1	94.12 ± 0.07	96.06 ± 0.31	7.79 ± 0.22	9.56 ± 0.20
PCA Avg. Root	10×1	93.74 ± 0.10	95.82 ± 0.45	8.32 ± 0.47	10.69 ± 0.31
PCA Avg. Root (Seg.)	16×1	93.76 ± 0.09	95.85 ± 0.30	8.31 ± 0.34	10.45 ± 0.24
PCD	8×1	94.85 ± 0.06	96.65 ± 0.31	6.94 ± 0.39	7.84 ± 0.13
PCD (Seg.)	19×1	94.30 ± 0.10	96.23 ± 0.26	7.62 ± 0.32	9.20 ± 0.15
ICA 99%	36×1	94.69 ± 0.10	96.44 ± 0.17	7.04 ± 0.19	8.33 ± 0.22
ICA 99% (Seg.)	49×1	94.53 ± 0.09	96.55 ± 0.23	7.46 ± 0.25	8.66 ± 0.26
ICA 97%	15×1	94.21 ± 0.11	96.27 ± 0.45	7.83 ± 0.32	9.43 ± 0.33
ICA 97% (Seg.)	31×1	94.11 ± 0.07	95.97 ± 0.28	7.73 ± 0.29	9.65 ± 0.23
ICA Avg. Root	10×1	93.76 ± 0.12	96.07 ± 0.17	8.53 ± 0.22	10.64 ± 0.30
ICA Avg. Root (Seg.)	16×1	93.73 ± 0.07	96.14 ± 0.26	8.65 ± 0.27	10.41 ± 0.22
ICA-PCD	8×1	94.94 ± 0.04	96.49 ± 0.16	6.58 ± 0.20	7.77 ± 0.10
ICA-PCD (Seg.)	19×1	94.31 ± 0.09	96.18 ± 0.23	7.54 ± 0.21	9.30 ± 0.21

Ao comparar-se estes resultados com os obtidos com classificadores neurais (vide Tabela 8.4), nota-se, para o SP máximo, que a maior diferença, entre as duas versões de classificadores, ocorre no caso da extração segmentada dos componentes independentes, após a redução de 3% no valor de energia de cada segmento (ICA-97%). Esta máxima diferença foi de 0,95 ponto percentual, enquanto que a mínima diferença (0,15 ponto percentual) ocorreu entre os classificadores alimentados com as fontes independentes obtidas após a projeção nos componentes principais de discriminação. Estes resultados mostram que, a decorrelação não linear, aplicada em um base não linear foi capaz de evidenciar a tal ponto a informação discriminante de cada classe, que um discriminador linear conseguiu resultados estatisticamente similares aos obtidos com a adoção de redes neurais alimentadas com anéis sem qualquer espécie de pré-processamento adicional.

8.7 Eficiência Computacional dos Métodos

O custo computacional de cada abordagem será considerado como o número de multiplicações e acumulações (MAC) realizadas do momento que os anéis foram produzidos¹, até a produção do resultado final pelo bloco classificador. Considerando $\mathbf{x} \in \mathbb{R}^{100}$ um vetor coluna contendo os 100 anéis produzidos pelo algoritmo de anelamento, a saída (o) do classificador não linear será dada por

$$\mathbf{x}_p = \prod_{j=1}^N \mathcal{F}(\mathbf{W}_{p_j} \mathbf{x}) \quad (8.4)$$

$$o = \tanh(\mathbf{w}_o \tanh(\mathbf{W}_i \mathbf{x}_p)) \quad (8.5)$$

onde N é o número de projeções a serem realizadas na etapa de pré-processamento, \mathbf{W}_{p_j} é a j -ésima matriz de projeção (PCA, PCD, etc.) a ser aplicada a \mathbf{x} , \mathbf{W}_i é a matriz de pesos sinápticos da camada escondida da rede neural, \mathbf{W}_o é o vetor de pesos sinápticos do neurônio de saída e $\mathcal{F}(\cdot)$ é uma função que será a tangente hiperbólica, no caso de projeção via PCD, e linear ($x = y$) em todos os demais casos. Para o classificador linear, a saída será dada por

$$o = \tanh(\mathbf{w}_o \mathbf{x}_p) \quad (8.6)$$

Para o caso de projeção segmentada, uma única matriz de projeção pode ser adotada fazendo-se

$$\mathbf{W}_p = \begin{bmatrix} \mathbf{W}_{PS} & 0 & \cdots & 0 \\ 0 & \mathbf{W}_{EM1} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \mathbf{W}_{HD3} \end{bmatrix} \quad (8.7)$$

onde \mathbf{W}_{PS} , \mathbf{W}_{EM1} , ..., \mathbf{W}_{HD3} são as matrizes de projeção de cada camada.

A primeira vista, pode-se pensar em calcular o custo computacional total (T) de cada abordagem fazendo-se:

$$T = T_p + T_c \quad (8.8)$$

¹Excluindo-se o tempo gasto para a geração dos anéis.

onde T_p é o número de MAC realizadas no pré-processamento dos anéis, e T_c é o número de MAC realizadas pelo bloco de classificação. Por exemplo, o número de MAC necessárias para a produção do resultado de classificação pela abordagem via ICA não segmentada, com corte em 99% da energia via PCA, e empregando um classificador neural, será

$$T_p = 36 \times 100 + 36 \times 36$$

$$T_c = 36 \times 10 + 10$$

$$T = 5.266 \text{ MAC}$$

onde, T_p é o número de MAC necessárias para fazer, inicialmente a projeção nos 36 componentes principais, mais o número de MAC requeridas para projetar esses 36 componentes extraídos na base de componentes independentes. T_c , por sua vez, é a soma do número de MAC requeridas para propagar a entrada pré-processada $x_p \in \mathbb{R}^{36}$ pelo classificador neural contendo 10 neurônios na camada escondida.

Entretanto, pode-se explorar a linearidade existente em quase todas as projeções calculando-se, *a priori*, o produtório $\prod_{j=1}^N \mathbf{W}_{p_j} \mathbf{x}$, e projetando este resultado em \mathbf{W}_i (ou \mathbf{w}_o para o discriminador linear), fundindo-se as matrizes de pré-processamento e a matriz de pesos da primeira camada escondida da rede neural em uma única matriz \mathbf{W}_{pc} . Com isso, a saída do classificador será dada, para o caso neural, por

$$o = \tanh(\mathbf{w}_o \tanh(\mathbf{W}_{pc} \mathbf{x})) \quad (8.9)$$

Para o exemplo do classificador alimentado com os componentes independentes, após corte em 99% da energia, tem-se, empregando a equação 8.9, $T = 100 \times 10 + 10 = 1.010$ MAC, o que representa uma redução de $\sim 81\%$ no número de MAC.

Entretanto, dependendo do número de componentes (N_c), e do número de neurônios (N_n) na camada escondida da rede neural, esta otimização pode acabar produzindo resultados piores, do ponto de vista de número de MAC. Para que a otimização sugerida produza ganhos computacionais, deve-se fazer

$$N_c > \frac{N \times N_n}{N + N_n} \quad (8.10)$$

Tabela 8.7: Número de operações de multiplicação e acumulação (MAC).

Abordagem	Neural	Relevância	Fisher
Anéis Puros	1.010	250	100
PCA 99%	1.010	303	100
PCA 99% (Seg.)	1.010	303	100
PCA 97%	1.010	303	100
PCA 97% (Seg.)	856	166	100
PCA Avg. Root	505	303	100
PCA Avg. Root (Seg.)	558	166	100
PCD	808	100	808
PCD (Seg.)	780	420	599
ICA 99%	1.010	1.010	100
ICA 99% (Seg.)	1.010	1.010	100
ICA 97%	1.010	303	100
ICA 97% (Seg.)	856	244	100
ICA Avg. Root	505	100	100
ICA Avg. Root (Seg.)	558	255	100
ICA-PCD	827	415	808
ICA-PCD (Seg.)	780	516	599

onde N é a dimensão original dos eventos (100 no caso dos anéis). É fácil concluir que esta otimização sempre será benéfica no caso do classificador linear. Para o caso segmentado, deve-se levar em consideração a dimensão de cada camada, de tal forma que fusão de matrizes só deve ser feita quando

$$\sum_{i=1}^M (N_i + N_n) \times N_{c_i} > N \times N_n \quad (8.11)$$

onde M é o número de camadas (7 no caso deste trabalho), N_i é a dimensão original dos anéis de cada camada, e N_{c_i} é o número de componentes selecionados em cada camada, após a compactação via PCA, PCD, etc.

No caso onde componentes principais de discriminação são empregados, tem-se $\mathcal{F}(x) = \tanh(x)$. Nestas situações, a fusão direta de matrizes não é possível, dada a não linearidade introduzida por \mathcal{F} . Entretanto, a fusão pode ser particionada, sendo realizada para todas as projeções a serem realizadas antes da aplicação de \mathcal{F} , e para as projeções após a aplicação de \mathcal{F} .

Baseado nestas análises, a Tabela 8.7 apresenta o número de MAC de cada abordagem, aplicando a fusão de matrizes em todos os casos não segmentado que satisfizeram a inequação 8.10 e os casos segmentados que satisfizeram a inequação 8.11. Para o caso neural, a abordagem computacionalmente mais veloz foi a ICA após compactação via PCA segundo o critério *Average Root*. Comparada ao melhor resultado de eficiência obtido (ICA compactada 99% da energia via PCA), a técnica mais veloz ofereceu um SP apenas 0,75% pior, porém empregando $\sim 45\%$ menos MAC para produzir a resposta do classificador.

Comparando-se os resultados obtidos após a análise da relevância com os obtidos com o discriminador de Fisher, observa-se que, em quase todas as abordagens, a implementação de um classificador linear proveu resultados computacionalmente menos custosos do que a abordagem de corte de componentes via relevância. Adicionalmente, em quase todos os casos, o discriminador linear ofereceu eficiências de classificação superiores às obtidas com compactação por relevância. Entretanto, a análise da relevância apresenta a vantagem de operar como uma espécie de controle que permite ajustar o ponto ótimo entre velocidade de execução e eficiência de classificação, o que na dinâmica de funcionamento do sistema de filtragem do ATLAS, significa uma excelente característica.

8.8 Vantagens da Abordagem Segmentada

A extração segmentada, ao longo deste capítulo, mostrou ser uma maneira bastante eficiente de observar as especificidades de cada camada, apresentando-as com igual peso para a parte classificadora. Com exceção da análise de componentes principais de discriminação, em todos os casos, a extração independente das características de cada camada ofereceu melhores ganhos no que tange a eficiência de classificação. A abordagem segmentada também traz, como ganho adicional, a possibilidade de se saber como cada camada contribui para a produção da decisão pelo classificador.

No quesito custo computacional, ao contrário do que se poderia supor inicialmente, a abordagem segmentada pode oferecer, mesmo empregando um número maior de componentes, custos computacionais mais baixos. Por exemplo, a abordagem via PCA com critério de corte em 97% da energia, para o caso neural, empregou

$\sim 100\%$ mais informação do que a sua correspondente não segmentada, custando, do ponto de vista computacional, $\sim 15\%$ menos, e ainda foi capaz de prover, para uma mesma probabilidade de detecção, um falso alarme 0,34 ponto percentual mais baixo.

8.9 Vantagens do Pré-Processamento Não-Linear

As análises realizadas neste capítulo mostraram que, para o problema abordado neste trabalho, o pré-processamento não linear joga um papel benéfico. O emprego de componentes principais de discriminação foi capaz de prover características sobre os sinais empregados que permitiram, mesmo a um classificador linear, atingir eficiências de classificação muito próximas das obtidas com a adoção de classificadores baseados em redes neurais. Ganhos também foram obtidos ao somar-se à esta projeção em uma base não linear, a descorrelação dos momentos de ordem superior dos dados. Esta descorrelação, que para os pré-processamentos lineares, não resultou em nenhum ganho para o classificador linear, permitiu, em uma base não linear, tornar a informação relevante à discriminação mais evidente, resultando em um positivo ganho para a eficiência de classificação.

As técnicas de pré-processamento não linear foram capazes de compactar com mais intensidade o espaço de entrada de sinais, mantendo, ainda sim, eficiências de detecção muito próximas dos obtidos com abordagens lineares de pré-processamento. Por exemplo, a PCD isolada proveu, com apenas 8 componentes, eficiência ligeiramente superior à obtida com os 36 componentes extraídos via PCA não segmentada, mesmo empregando $\sim 78\%$ menos variáveis. A utilização de um menor número de componentes trouxe impacto direto no custo computacional associado à estas abordagens não lineares.

Capítulo 9

Resultados com Dados

Experimentais

Recentemente, enquanto o LHC ainda não entrara em operação, os testes finais do ATLAS foram realizados com raios cósmicos [27]. Estes raios cósmicos podem contribuir com a validação dos algoritmos de filtragem desenvolvidos com simulações de Monte Carlo, pois estes dados experimentais permitem observar o perfil real do ruído produzido pelo experimento. Também torna-se possível verificar situações anômalas que naturalmente ocorrem durante a operação nominal, como a perda de células dos calorímetros, por exemplo.

Ao final de 2009, as primeiras colisões foram realizadas pelo LHC, com 2,2 TeV de energia no centro de massa, o que já o coloca como o mais poderoso acelerador de partículas em funcionamento no mundo. Ao final destas colisões, uma pequena massa de dados foi disponibilizada à colaboração para análise de seus algoritmos.

Entretanto, diferentemente das simulações de Monte Carlo, na análise com dados experimentais, nunca se tem absoluta certeza sobre o tipo de partícula incidente. Neste caso, a palavra final sobre o tipo de partícula é dada por algoritmos *offline*. Estes algoritmos, como não possuem restrição de tempo, podem ser suficientemente complexos e combinar a informação de vários subdetetores ao mesmo tempo para analisar cada evento, provendo altas taxas de eficiência.

Nenhuma destas análises com dados experimentais seria possível sem que, primeiramente, o algoritmo de classificação proposto neste trabalho fosse inserido no sistema de filtragem *online*. Para esta inserção, não só a eficiência de classificação

deve ser validada, mas, também, a capacidade do sistema proposto em prover um resultado em um tempo compatível com o requerido para o L2. Desta forma, a parte final deste capítulo apresenta todo o processo de migração deste trabalho para o ambiente Athena, e a consequente validação de sua capacidade de operação *online*.

9.1 Validação com Raios Cósmiticos

Raios cósmicos são elementos radioativos provenientes do espaço sideral, e são composto, em 90%, por prótons, e o restante, por partículas α . Ao interagirem com a atmosfera terrestre, estes raios cósmicos entram em um processo de decaimento que resulta em diversas partículas, inclusive múons [91]. Estes múons são as únicas partículas que, de fato, atingem a crosta terrestre, sendo tão energéticos, que são capazes de atingir o ATLAS situado a 100 metros de profundidade. Conseqüentemente, a análise da interação destes múons com os detetores do ATLAS pode ser utilizada para a validações destes.

Múons, tal como elétrons, estão sujeitos apenas à interações eletromagnéticas ao interagir com a matéria. Entretanto, para a mesma faixa de energia, múons se comportam de maneira bastante distinta. Até energias bastante elevadas (acima de 100 GeV), múons perdem sua energia principalmente através da ionização do material ou através da produção de raios- δ . Produção de pares e^+e^- e *bremsstrahlung* também podem ocorrer durante a interação de múons com a matéria. Entretanto, comparado a elétrons, a perda de energia por estes 2 últimos processos é aproximadamente 40.000 vezes menor, para a mesma faixa de energia [13].

Existem estudos sendo conduzidos no ATLAS que estão interessados na análise de raios cósmicos. Entretanto, para o canal elétron / jato, estes raios cósmicos são considerados ruído de fundo, de forma que devem ser rejeitados pelo sistema de filtragem do ATLAS.

9.1.1 Característica dos Eventos

Para a análise da característica destes eventos provenientes de radiação cósmica, 26.347 eventos foram empregados. É apresentada, na Figura 9.1 a distribuição em E_T , η e ϕ destes eventos. De acordo com [92], a distribuição esperada em energia

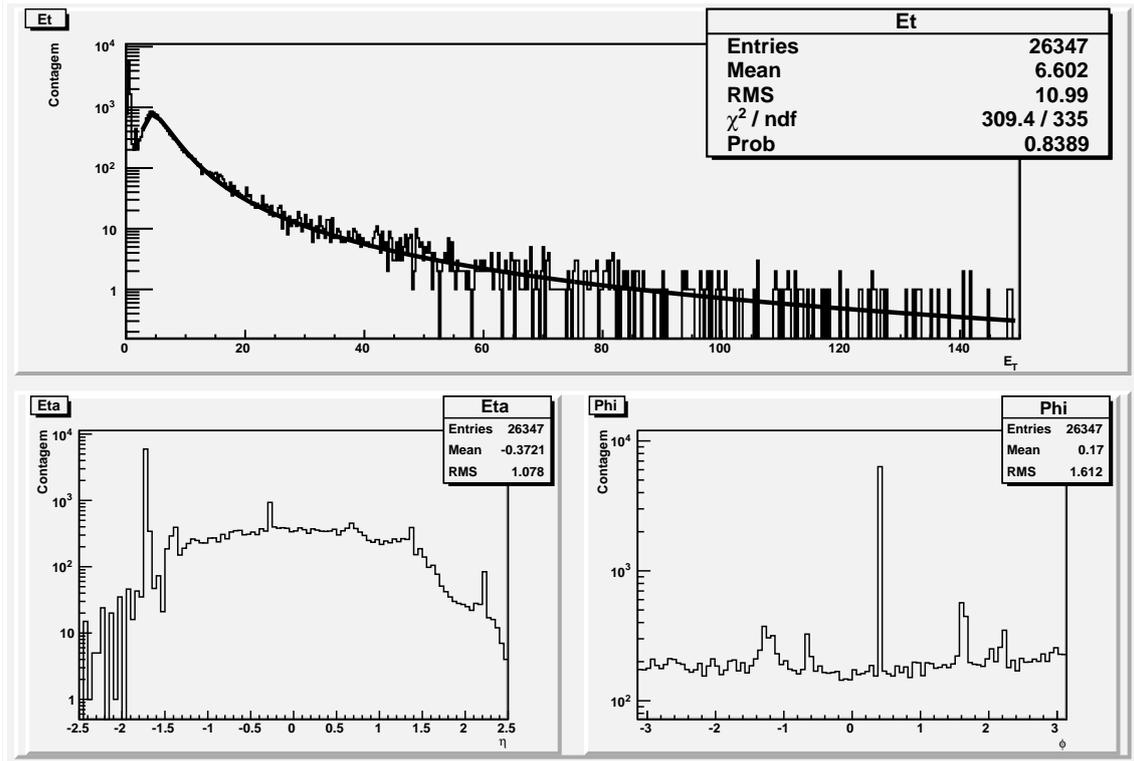


Figura 9.1: Distribuição em E_T , η e ϕ para os raios cósmicos.

para estes eventos pode ser modelada por uma função landau convoluída com uma gaussiana. Ao realizar-se o *fitting* da distribuição de energia obtida para estes raios cósmicos com o modelo teórico proposto, obteve-se um grau de confiabilidade de $\sim 84\%$, mostrando que a distribuição em E_T está condizente com o modelo teórico.

Em η , a distribuição de eventos não é uniforme. Isto acontece dada a proveniência da radiação cósmica que atinge o detetor ATLAS. Como vêm do espaço, a probabilidade maior é que estas partículas incidam perpendicularmente no ATLAS, o que explica a maior concentração de eventos para valores mais baixos (em módulo) de η . Em relação a ϕ , observa-se uma distribuição mais uniforme.

Nos 3 histogramas apresentados na Figura 9.1, nota-se um grande pico. Na Figura 9.2 (gráfico da esquerda), observa-se que este pico corresponde a eventos localizados na região próxima de $(\eta; \phi) = (-1, 7; 0, 4)$. No gráfico da direita, ainda na Figura 9.2, observa-se que, nesta região, todos os eventos estão com muito baixa energia ($E_T < 2$ GeV). O problema é que o primeiro nível de filtragem foi projetado para cortes, em energia, no mínimo em 2 GeV. Para a aquisição dos raios cósmicos, o corte em energia do L1 foi reduzido para valores muito mais baixos do que 2 GeV. Estando fora de sua faixa de operação, a eletrônica do L1 funciona mal e, neste

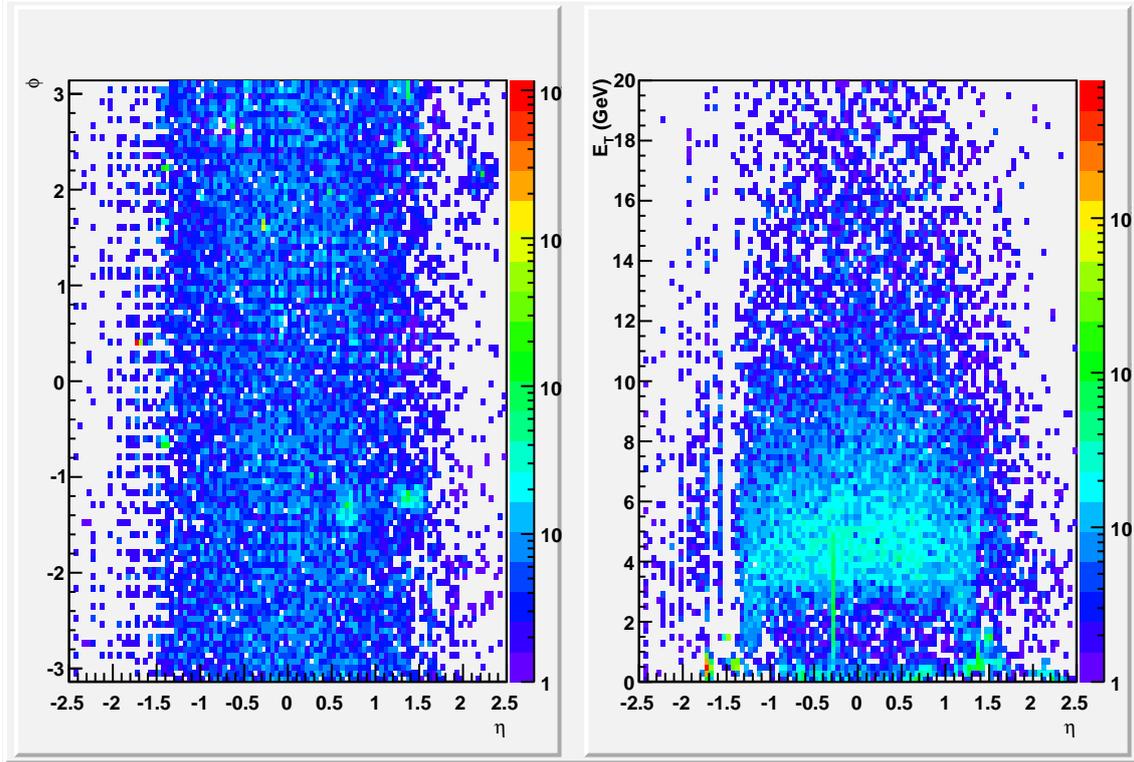


Figura 9.2: Distribuição dos eventos em função de η e ϕ (à esquerda), e em função de η e E_T (à direita).

caso, fica permanentemente acusando a presença de um evento fictício, que não existe na realidade. Problemas similares ocorreram, em menor escala, em outras regiões próximas, como $(\eta;\phi) = (0,7;-1,27)$ e $(\eta;\phi) = (-1,5;-0,68)$ (veja o gráfico da esquerda na Figura 9.2). Como um corte tão baixo em energia pelo L1 é um caso que não se verá na prática, pode-se eliminar estes eventos fantasmas aplicando-se um corte em 2 GeV. Desta forma, a Figura 9.3 apresenta as mesmas distribuições em E_T , η e ϕ para os eventos com $E_T > 2$ GeV. Observa-se que os picos correspondentes a estes eventos desapareceram.

Após este corte em energia, 2 picos ainda se fazem visíveis. Um pico na região $(\eta;\phi) = (-0,3;1,6)$ e outro na região $(\eta;\phi) = (1,4;-1,2)$. Para o primeiro pico, analisou-se o perfil de deposição de energia dos eventos nesta região. A Figura 9.4 apresenta a deposição de energia nas 4 camadas eletromagnéticas para um destes eventos. Nota-se que, com a exceção da EM2, as camadas contêm apenas ruído. É bastante inviável que um evento deposite energia apenas na EM2, e não deposite nada nas outras camadas eletromagnéticas. Conclui-se, portanto, que se trata de um evento “fantasma”. Eventos fantasmas são resultado de problemas em células dos

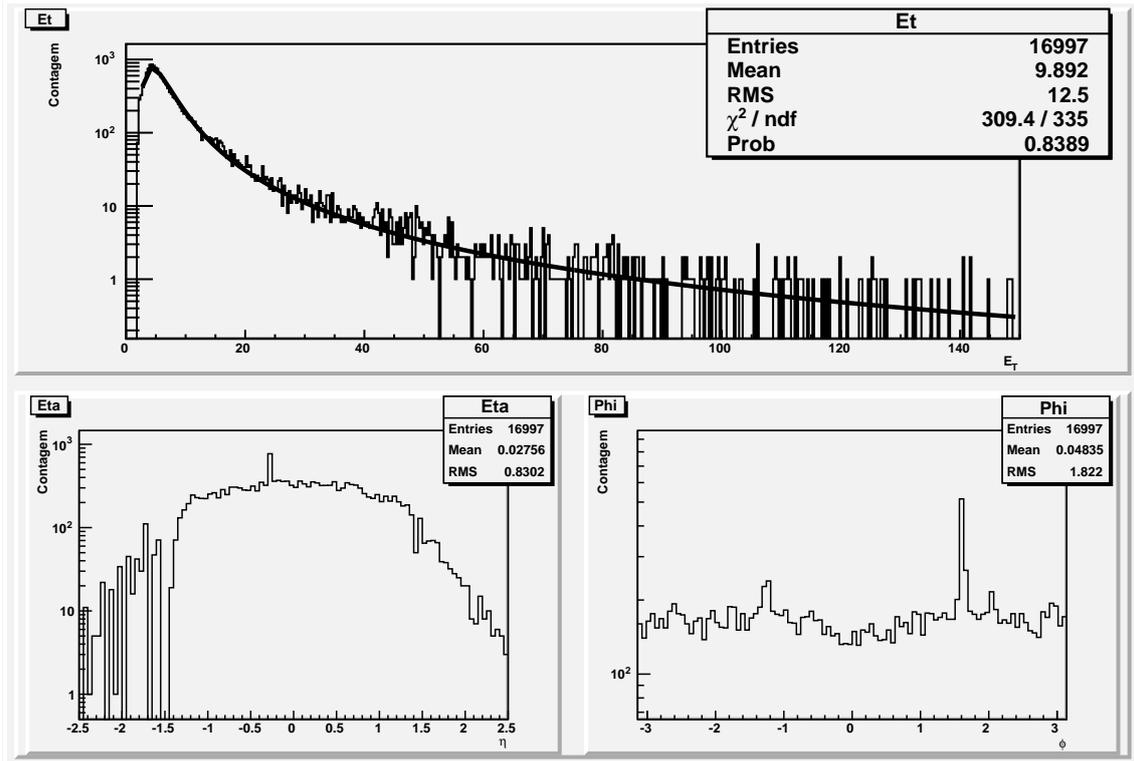


Figura 9.3: Distribuição dos eventos em função de η e ϕ (à esquerda), e em função de η e E_T (à direita).

calorímetros, que enviam um sinal acusando a passagem de um evento, quando na verdade nenhum evento foi recebido. Conseqüentemente, somente estas células ficam “quentes”, enquanto que as demais células da EM2 e das outras camadas não acusam nenhuma interação. No caso do pico próximo à $(\eta; \phi) = (1,4; -1,2)$, a mesma análise foi repetida, e, conforme apresentado na Figura 9.5, o problema ocorre pelas mesmas razões, porém ao invés das células problemáticas estarem na EM2, elas estão na EM1.

9.1.2 Eficiência do Sistema de Classificação Proposto

Para a análise da eficiência de classificação, utilizou-se uma versão, já implementada no Athena, do algoritmo de discriminação elétron / jato. Esta versão, à época da aquisição de dados, empregava uma rede neural artificial com 18 neurônios na camada escondida, e utilizava normalização sequencial dos anéis produzidos (vide a Seção 7.2.5). Por fim, nenhum pré-processamento estatístico foi realizado.

A Figura 9.6 apresenta a distribuição dos valores obtidos no neurônio de saída

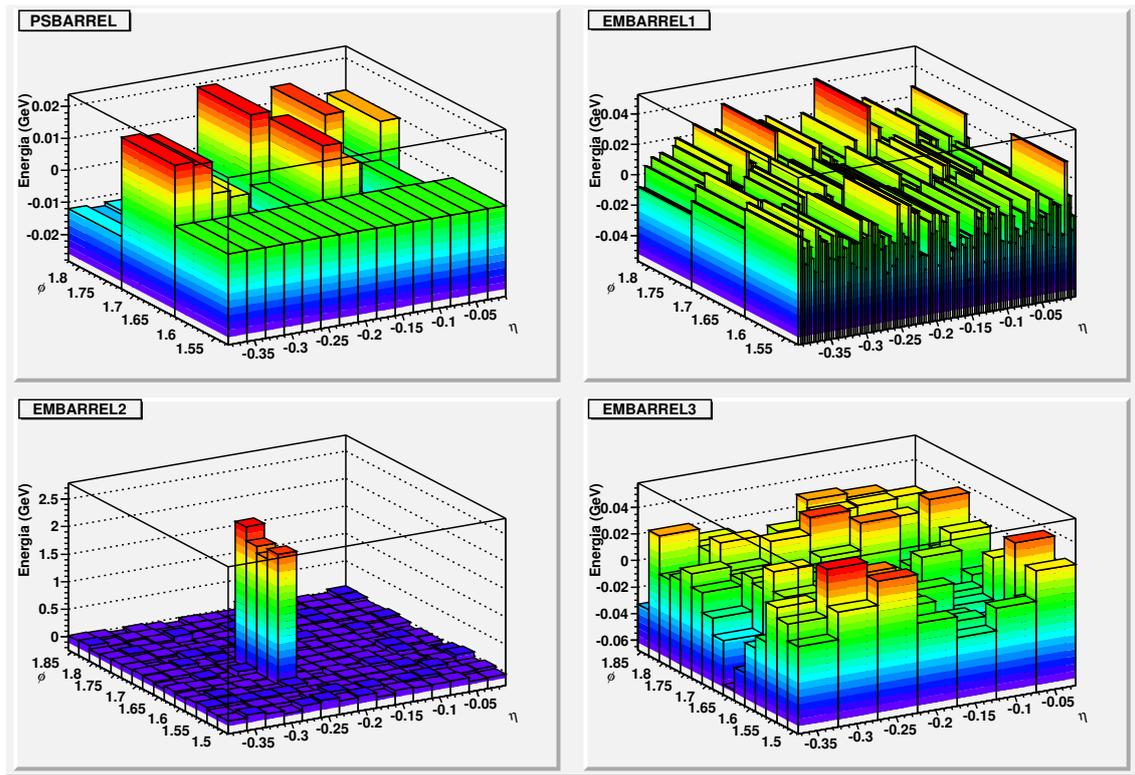


Figura 9.4: Exemplo de um evento fantasma na região centrada em $(\eta; \phi) = (-0,3; 1,6)$.

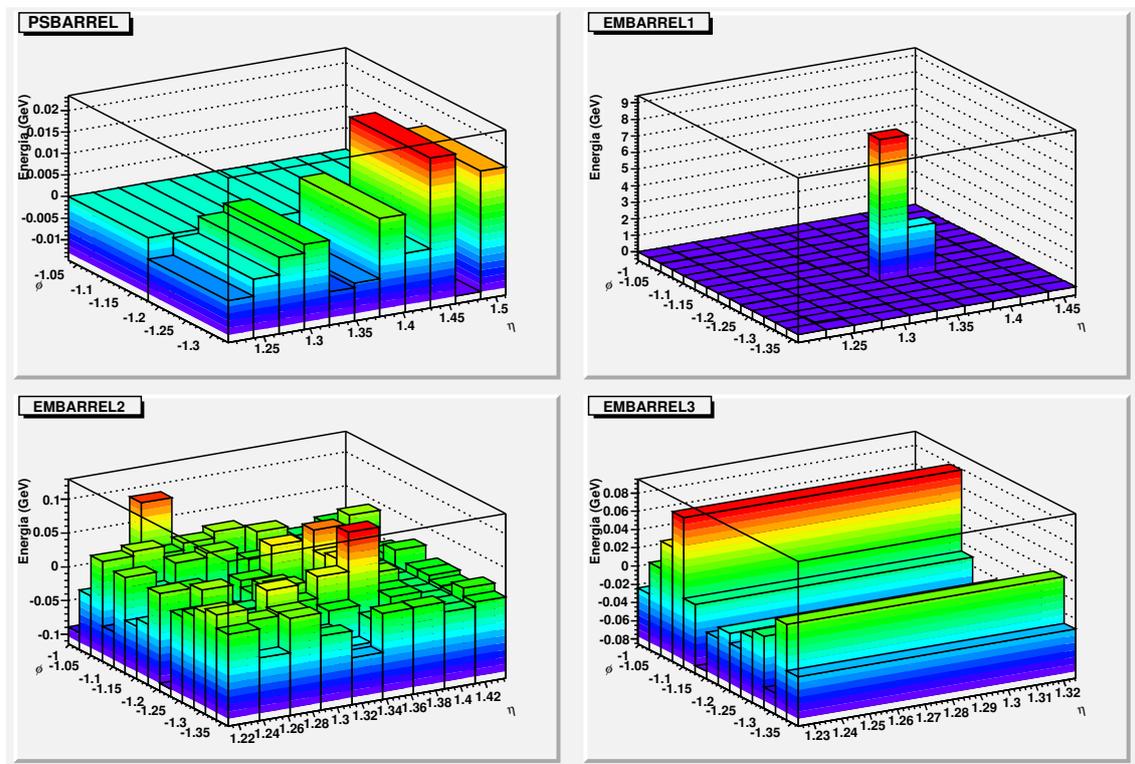


Figura 9.5: Exemplo de um evento fantasma na região centrada em $(\eta; \phi) = (1,4; -1,2)$.

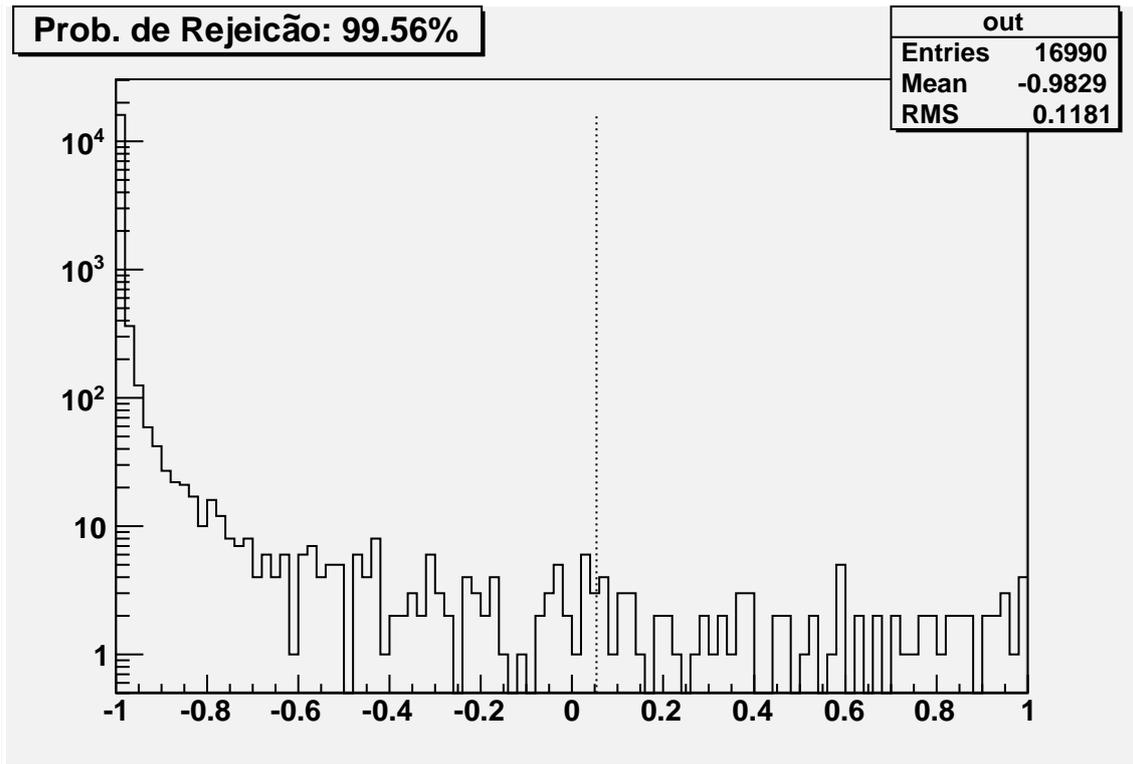


Figura 9.6: Saída do classificador neural para raios cósmicos. A linha tracejada representa o limiar de corte.

da rede neural. Observa-se que este classificador foi capaz de rejeitar 99,56% dos eventos. Na Figura 9.7, apresenta-se o perfil médio dos anéis erroneamente aprovados pelo classificador (em cima), e o perfil médio dos raios cósmicos corretamente rejeitados pelo classificador neural. Como referência, apresenta-se, também, o perfil médio de elétrons e jatos. Os eventos corretamente rejeitados possuem um perfil bem mais próximo do perfil de jatos, o que justifica serem rejeitados. Já os eventos erroneamente aprovados possuem um perfil bem semelhante à elétrons. Em alguns raros casos, múons, ao interagirem com o calorímetro, podem produzir fótons e pares e^-e^+ . Estes eventos, então, seriam capazes de produzir um chuva eletromagnético, tornando o perfil de deposição de energia deste múons muito parecida com a de elétrons.

O T2Calo, para os mesmos eventos, fornece uma eficiência de rejeição de 98.21%. A Figura 9.8 apresenta como o número de eventos reduz-se a cada corte aplicado. Nota-se que os corte mais abruptos são feitos logo pelos 2 primeiros cortes. Nota-se, também, que o corte analisando o vazamento de energia para a seção hadrônica não exerce praticamente nenhuma influência na decisão final do T2Calo.

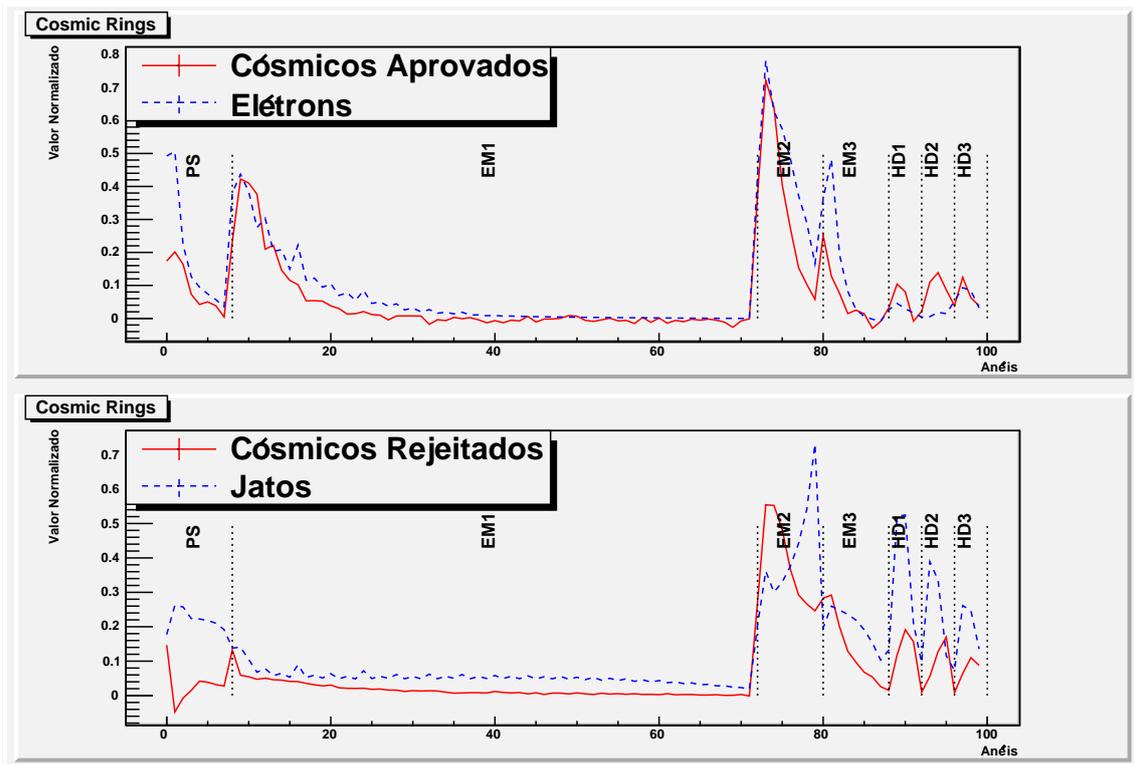


Figura 9.7: Formato médio dos cósmicos aprovados (em cima) e rejeitados (em baixo). O formato médio de elétrons e jatos também é apresentado como referência.

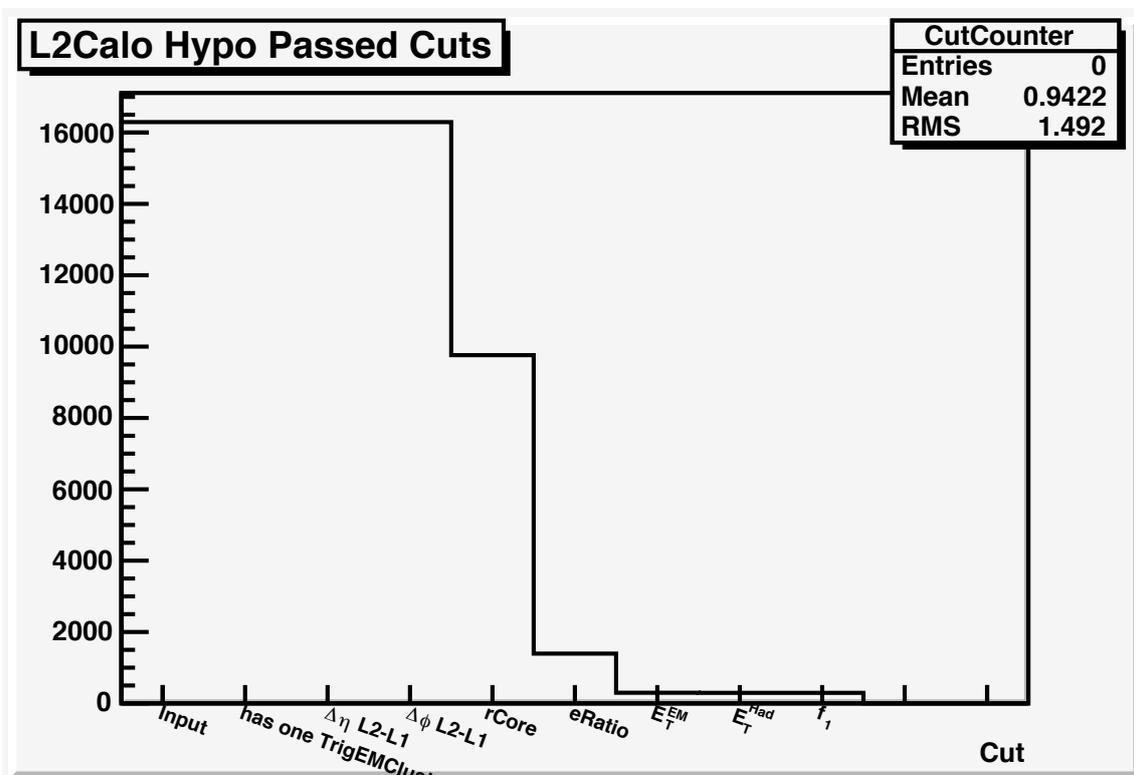


Figura 9.8: Evolução na redução do número de eventos a cada corte aplicado pelo T2Calo.

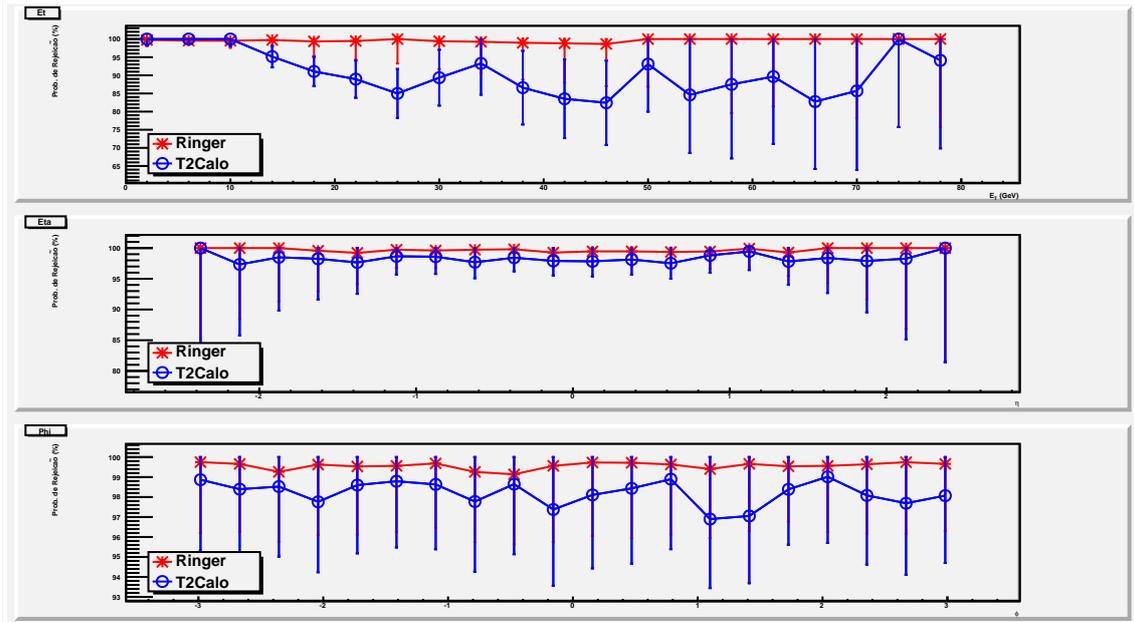


Figura 9.9: Probabilidades de rejeição em função de E_T (em cima), η (no centro) e ϕ (embaixo) entre o classificador neural e o T2Calo.

Por fim, a Figura 9.9 apresenta a comparação entre as probabilidades de rejeição de múons em função de E_T , η e ϕ , tanto para o classificador neural, bem como para o T2Calo. Nota-se que a versão neural mantém uma alta eficiência de rejeição ao longo destas 3 grandezas. O T2Calo, embora apresente probabilidades de rejeições bastante uniformes em η e ϕ , apresenta uma crescente queda da probabilidade de rejeição conforme a energia transversa aumenta.

9.2 Resultados com Dados de Colisão

Ao final de 2009, o LHC entrou em operação para testes em baixas energias, colidindo prótons com 2,2 TeV no centro de massa. Observa-se, na Figura 9.10, a interação dos eventos provenientes das colisões do LHC com os calorímetros do ATLAS. As células de granularidade mais fina correspondem ao calorímetro eletromagnético, e as com maiores dimensões, ao calorímetro hadrônico. Na parte central da figura, observam-se dois eventos, depositando energia tanto na seção eletromagnética quanto hadrônica, o que caracteriza o perfil de jatos.

A versão do classificador neural empregada para a análise de dados de colisão foi a mesma que a empregada para a análise de raios cósmicos (normalização sequencial

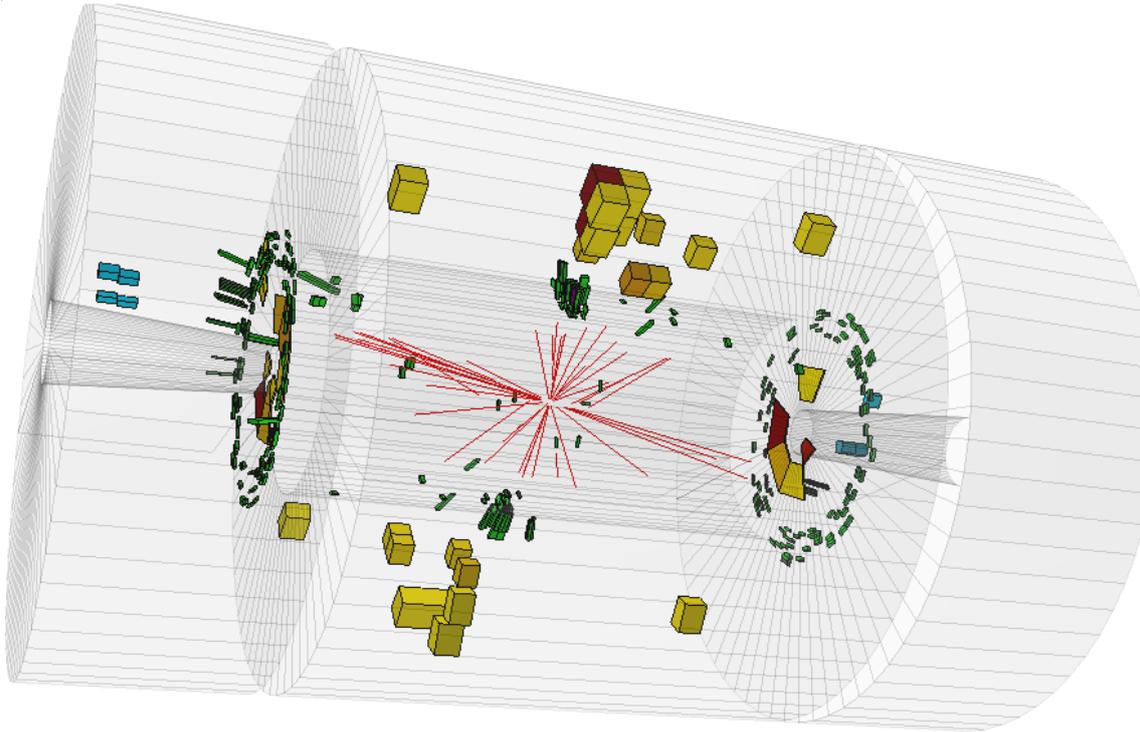


Figura 9.10: Visualização da interação com o ATLAS dos eventos provenientes de colisões do LHC.

e topologia $100 \times 18 \times 1$). Apenas 848 eventos foram disponibilizados para análise. Destes 848, 214 foram classificados, através de algoritmos *offline*, como elétrons. Para estes eventos classificados como elétrons pelo algoritmo *offline*, a versão neural identificou, também como elétrons, 21,03% destes, enquanto que o T2Calo só identificou 10,75% destes elétrons. A baixa eficiência de ambos os algoritmos deve-se ao fato de que calorímetros possuem ótima resolução de energia apenas em altas energias. Na faixa de energia na qual encontram-se estes dados, a resolução tende a ser consideravelmente mais baixa, o que dificulta a identificação de partículas baseada apenas na deposição de energia no sistema de calorimetria.

Para os eventos de colisão obtidos, a Figura 9.11 apresenta a eficiência, para o classificador neural e o T2Calo, em função de E_T , η e ϕ . Para as 3 grandezas, a versão neural sempre apresenta os melhores resultados. Na variação da eficiência em função de E_T , nota-se que a eficiência tende a aumentar para os 2 algoritmos, conforme a energia transversa aumenta. Para energias acima de 5 GeV, a análise fica bastante comprometida, dada a baixa quantidade de eventos nestas regiões.

A análise com dados de colisões, permitiu, mesmo com um número reduzido de

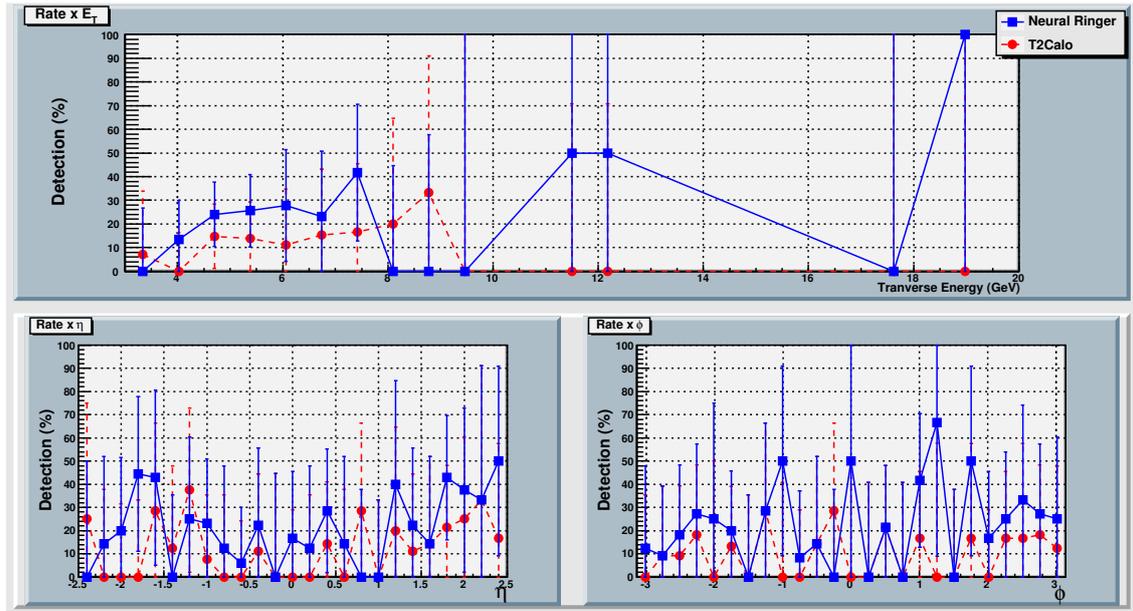


Figura 9.11: Eficiência de detecção de elétrons para o sistema proposto e o T2Calo.

eventos, comprovar a superioridade do modelo baseado em redes neurais alimentadas com informação topológica baseada em soma em anéis. Uma eficiência quase 100% superior ao T2Calo foi obtida. Entretanto, mais dados (ainda não disponibilizados pela colaboração ATLAS) se fazem necessários para que resultados mais conclusivos possam ser fornecidos, e novas comparações entre as duas implementações, realizadas.

9.3 Implementação no Athena

Em pesquisas anteriores [44, 45] para separação elétron-jato no segundo nível de filtragem do ATLAS, os dados para análises eram obtidos alterando-se o código do T2Calo no Athena para que o mesmo, ao acessar as células de cada RoI, salvasse as mesmas em um arquivo texto, que era, então, utilizado para análises. Esta abordagem, embora permitisse o andamento das pesquisas, tinha sérios problemas. A cada nova versão disponível do Athena, esta alteração no T2Calo precisava ser refeita. Adicionalmente, os resultados obtidos com os dados extraídos desta maneira eram vistos com desconfiança pela colaboração ATLAS, visto que as análises não eram feitas pelas ferramentas de análise fornecidas pela colaboração.

Desta forma, a primeira etapa para a análise dos dados foi conquistar, junto à

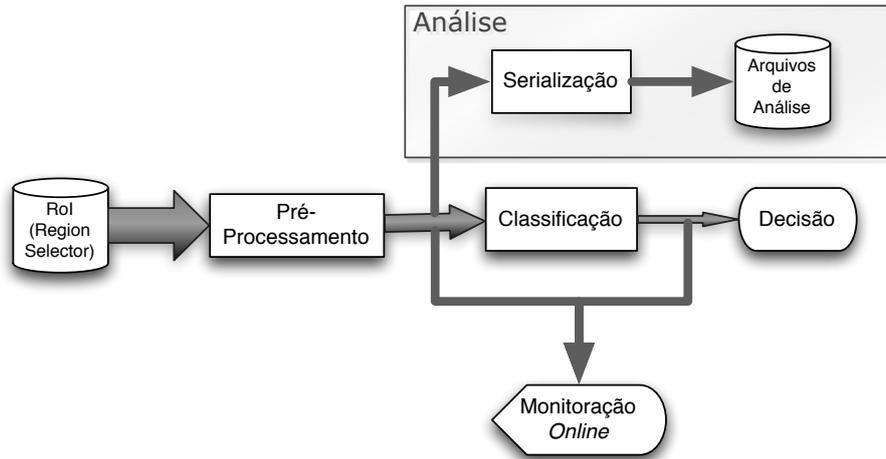


Figura 9.12: Fluxo de informação pelos pacotes empregados para a filtragem de eventos no Athena.

colaboração ATLAS o direito a um pacote oficial de desenvolvimento de algoritmos de discriminação elétron / jato. Este pacote passou a ser chamado de *Ringer*, e encontra-se totalmente sob o controle da UFRJ. Adicionalmente, o *Ringer* passa a ser parte integrante das futuras versões do Athena.

Os algoritmos destinados à filtragem *online* de eventos devem atender a um esquema de particionamento específico do processamento. Este esquema é apresentado na Figura 9.12. Nesta figura, os 3 retângulos representam os 3 componentes base que um dado algoritmo de filtragem precisa implementar. Um realiza o pré-processamento da informação proveniente da RoI, extraindo informações relevantes à classificação. O bloco de classificação aplica o teste de hipótese para determinar se o evento deve ou não ser aceito. Por último, o bloco de *serialização* é responsável por acessar as informações produzidas durante a fase de pré-processamento, e formatá-las para que sejam salvas em arquivos em disco, em um formato que permita a análise *offline*. É importante lembrar que este último bloco só é utilizado para extrair informações que permitam o desenvolvimento de novas técnicas de processamento de sinais ou a depuração de técnicas já implementadas. Desta forma, durante a operação nominal do sistema de filtragem, este bloco fica inativo, e a monitoração destas variáveis é feita somente através de histogramas *online* produzidos automaticamente pelo módulo de monitoração *online*. Este último, também provê análise de tempos de execução de cada módulo de execução.

9.3.1 Algoritmo de Anelamento

A primeira versão do algoritmo de produção e normalização dos anéis, implementada no Athena, origina-se de um pacote *offline* de análise desenvolvido em [44]. Este pacote, por ser originalmente destinado à análises *offline*, utilizava arquivos XML para descrever a configuração dos anéis a serem produzidos, o que não é o padrão oficial do Athena (que utiliza arquivos Python). Adicionalmente, por ser uma pacote de desenvolvimento, esta versão continha inúmeros pacotes úteis apenas para a análise destes anéis, enquanto que, em uma operação *online*, a quantidade (e conseqüentemente complexidade) de código deve ser minimizada, favorecendo a depuração e a execução veloz do algoritmo implementado.

Por originar-se de um pacote desenvolvido para operação *offline*, esta primeira implementação do algoritmo de anelamento repetia o cálculo de grandezas já produzidas pelo T2Calo (refinamento das coordenadas η e ϕ e cálculo da energia transversa do evento), o que se mostrava como uma duplicação desnecessária de código. Além disso, esta primeira versão tinha classes específicas para conter as células das RoI. Estas classe eram diferentes das utilizadas no Athena para o mesmo fim, de tal forma que muitas cópias de dados se faziam necessárias para que dados produzidos pelo pacote *offline* pudessem ser propagados pelo Athena, e vice-versa.

Por último, esta versão *offline* utilizava um algoritmo baseado em testes sucessivos para determinar a qual anel uma dada célula pertencia [44]. Ou seja: para cada célula de uma dada camada, o algoritmo verificava, anel a anel, se as coordenadas em $\eta \times \phi$ da célula pertenciam ao anel sendo testado. Este algoritmo era lento por dois motivos: primeiramente, o teste precisava ser feito anel a anel, até que o anel correto fosse encontrado. Em segundo lugar, testes condicionais são difíceis de serem otimizados pelo compilador, e, como representam uma quebra na cadeia de *pipeline* do processador, produzem significativo impacto na velocidade de execução.

Após esta primeira versão estar implementada no Athena, e com a experiência adquirida ao longo deste processo de migração, algumas otimizações do pacote foram realizadas. A modificação mais imediata, foi remover todo o código que não destinava-se a produção e normalização dos anéis, reduzindo consideravelmente a complexidade do código destinado à operação *online*. Neste processo de redução da complexidade do algoritmo, as funções encarregadas de realizar o cálculo da ener-

Tabela 9.1: Tempos para a criação dos anéis.

	Versão Original	Versão Otimizada
Tempo de Execução (μs)	$170,45 \pm 61,89$	$98,56 \pm 16,48$

gia transversa do evento, e do refinamento das coordenadas η e ϕ também foram descartadas, visto que já estavam implementados no T2Calo, o que tornava esta duplicidade de código desnecessária. Adicionalmente, o processo de configuração dos anéis via arquivos XML foi extinta, e um modelo de configuração baseado em arquivos em Python foi adotado em seu lugar.

Otimizações também foram realizadas no algoritmo de produção dos anéis. Ao invés de testes sucessivos, o algoritmo calcula o índice I_R do anel ao qual uma célula pertencerá empregando as equações 7.1, 7.2 e 7.3. Com esta otimização, não só o código ficou bem mais simples, como um grande impacto na velocidade de execução foi obtido, pois esta nova versão reduz o número de testes realizados, bem como, por basear-se em operações aritméticas, permite maiores otimizações do código, por parte do compilador e do processador. A Tabela 9.1 apresenta o tempo gasto pelo algoritmo de anelamento, antes e após as otimizações realizadas. Nota-se que as otimizações implementadas resultaram em uma queda de $\sim 42\%$ no tempo gasto por este algoritmo.

A última otimização empregada foi o algoritmo de anelamento ser incorporado ao T2Calo. O T2Calo possui diversos subalgoritmos, e, para as versões mais novas do Athena, o algoritmo de anelamento passa a ser um deles. A principal vantagem é a utilização de um objeto único que propaga tanto as variáveis do T2Calo, bem como os anéis produzidos, facilitando muito a integração do algoritmo de anelamento com os outros módulos do Athena. Adicionalmente, sendo parte integrante do T2Calo, não mais se faz necessário, pelo algoritmo anelador, refazer os cálculos de refinamento de E_T , η e ϕ , podendo este delegar ao T2Calo esta tarefa. Em resumo, no que tange a extração de características, o algoritmo de anelamento proposto e o T2Calo tornam-se parceiros. A diferença entre os dois, entretanto, é que o T2Calo realiza a decisão sobre o tipo de partícula incidente observando as 4 variáveis calculadas por ele, enquanto que o sistema proposto neste trabalho emprega redes neurais alimentadas

Tabela 9.2: Tempos de Execução do Algoritmo de Classificação (Rede $100 \times 18 \times 1$).

	Versão Original	Versão Otimizada
Tempo de Execução (μs)	$204,77 \pm 55,85$	$10,43 \pm 1,65$

com os anéis produzidos.

9.3.2 Teste de Hipóteses

O teste de hipóteses, tal como o algoritmo de anelamento, também teve a sua primeira versão oriunda do pacote de análises desenvolvido em [44]. Tal como o algoritmo de anelamento, esta primeira versão implementada no Athena utilizava arquivos XML para a descrição da rede neural a ser executada. Entretanto, o caso mais crítico era o processo de operação das redes neurais. Composto por um complexo conjunto de classes, este pacote permitia não só a operação (*feedforwarding*) de redes neurais, bem como o treinamento dela. Como foi concebido para ser extremamente genérico, perdeu-se muito em eficiência de execução.

Após a experiência adquirida ao implementar-se esta primeira versão no Athena, e a análise do seu funcionamento, uma nova versão foi desenvolvida. Esta nova versão foi simplificada ao ponto de permitir apenas a propagação dos eventos de entrada pelas camadas da rede neural. Adicionalmente, a topologia da rede a ser executada passou a ser descrita em arquivos Python, tal como padronizado pelos desenvolvedores do Athena. A Tabela 9.2 apresenta o tempo gasto para a propagação de um evento por uma rede com topologia $100 \times 18 \times 1$, com função de ativação tangente hiperbólica na camada escondida e de saída. Nota-se que as otimizações introduzidas permitiram que o tempo gasto com a propagação dos anéis pela rede neural fosse reduzida em, aproximadamente, 20 vezes.

9.3.3 Serialização

Este módulo foi desenvolvido para permitir que a informação de cada RoI, bem como os anéis produzidos pudessem ser serializados e exportados para arquivos em disco, possibilitando a análise *offline* destes. No Athena, existe um conjunto de classes que

implementam esta serialização. Logo, este módulo de serialização precisa apenas solicitar ao *Store Gate* às informações a serem serializadas, e passá-las às classes do Athena responsáveis por salvá-las em disco. O módulo de serialização, desta forma, exporta as seguintes variáveis:

- Os anéis produzidos em cada camada.
- O valor refinado da coordenada η .
- O valor refinado da coordenada ϕ .
- A energia transversa do evento.
- As informações de cada célula da RoI:
 - Posição em η .
 - Posição em ϕ .
 - Dimensão da célula em η .
 - Dimensão da célula em ϕ .
 - Código do subdetetor ao qual a célula pertence.
 - Energia da célula (em MeV).

Ao configurar-se o Athena para uma dada execução, é possível determinar quais pacotes deverão exportar seus dados para arquivos em disco. De forma que, em um mesmo arquivo, pode-se encontrar, por exemplo, os valores salvos pelo T2Calo e pelo algoritmo de anelamento desenvolvido. O arquivo salvo pelo Athena, é um arquivo compatível com a ferramenta de análise ROOT, permitindo que, a partir desta ferramenta, as informações salvas possam ser facilmente acessadas e analisadas.

Uma vez que estes 3 pacotes foram integrados oficialmente ao Athena, conquistou-se acesso direto e simplificado a um volume imenso de informação disponível para análises, aumentando pelo menos uma ordem de grandeza o número de eventos que, atualmente, encontram-se disponíveis para os estudos conduzidos na UFRJ. Esta integração também permite que os resultados produzidos possam ser confrontados com outros algoritmos do Athena (como o T2Calo, por exemplo), dentro deste próprio ambiente, como foi visto ao longo deste trabalho.

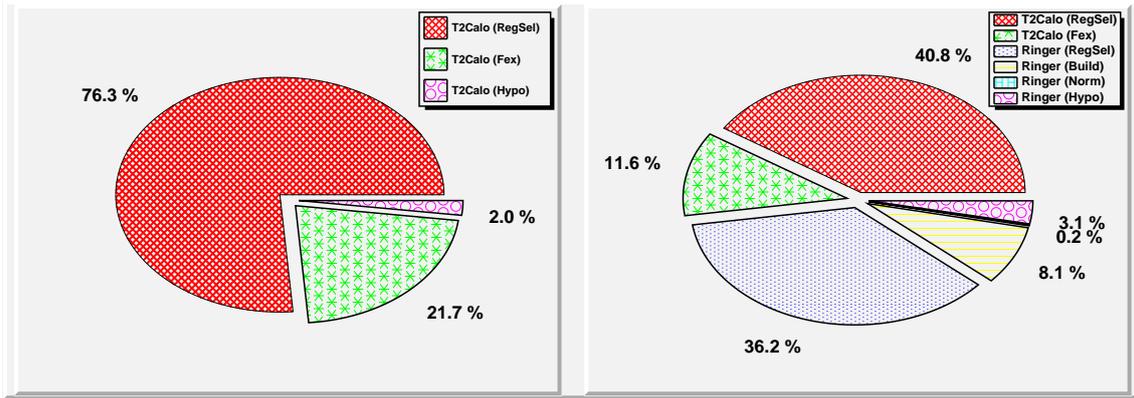


Figura 9.13: Percentual de tempo em cada etapa de processamento do T2Calo (à esquerda), e acrescido das etapas de processamento do sistema proposto (à direita).

9.3.4 Análise de Tempo do Algoritmo

Os resultados de eficiência apresentados provaram que o sistema de discriminação elétron / jato proposto está mais do que apto, no que tange a sua eficiência de classificação, à operar no segundo nível de filtragem do ATLAS. Entretanto, o sistema proposto, uma vez implementado no Athena, deve ser capaz de ser executado em um tempo compatível com as especificações exigidas para o L2.

Conforme dito anteriormente, o algoritmo de anelamento foi incorporado ao T2Calo, funcionando como um de seus subalgoritmos. Esta seção se dedicará a avaliar o custo computacional agregado ao adicionarmos o sistema proposto ao T2Calo, e ao empregarmos redes neurais para a classificação, ao invés dos cortes lineares do T2Calo.

Antes do algoritmo de pré-processamento ser executado, é necessário colher as informações das células pertencentes à RoI sendo analisada. Este processo é feito por um módulo chamado de *Region Selector*, que é responsável por solicitar aos ROS os fragmentos de informação da RoI desejada, desta forma para a análise de tempo, deve-se considerar o tempo gasto com esta etapa.

A Figura 9.13 apresenta, no gráfico à esquerda, o percentual de tempo gasto em cada etapa do T2Calo, quando operando sem o *Ringer*. Os valores absolutos de tempo estão descritos na Tabela 9.3a. Observa-se que o *Region Selector* ocupa, aproximadamente, 73% do tempo total de execução do T2Calo. Este tempo é, de fato, consideravelmente longo, dada a latência inerente à requisição de dados, à centenas de ROS, o que envolve transferência de dados via rede *Ethernet*, o que

Tabela 9.3: Tempo gasto em cada etapa de processamento.

(a) Apenas T2Calo.

Etapa	Tempo (μs)
<i>Region Selector</i>	$492,72 \pm 78,71$
Pré-processamento	$140,80 \pm 14,792$
Decisão	$13,16 \pm 4,43$
Total	$677,26 \pm 84,46$

(b) T2Calo com o *Ringer*

Etapa	Tempo (μs)
<i>Region Selector</i> (T2Calo)	$492,72 \pm 78,71$
Pré-processamento (T2Calo)	$140,80 \pm 14,792$
<i>Region Selector</i> (<i>Ringer</i>)	$437,50 \pm 99,57$
Pré-processamento (<i>Ringer</i>)	$98,56 \pm 16,48$
Normalização dos Anéis (<i>Ringer</i>)	$2,59 \pm 1,49$
Decisão (<i>Ringer</i>)	$38,68 \pm 1,785$
Total	$1.419,83 \pm 0,46$

tende a ser um processo lento. A seguir, com 21% do tempo total, vem a etapa de calcular as quatro variáveis que o T2Calo utilizará para sua decisão. Por fim, a decisão propriamente dita ocupa apenas 2% do tempo total, visto que é um processo bastante rápido, empregando apenas testes condicionais em cada uma das 4 variáveis calculadas na etapa de pré-processamento. O T2Calo, em média, leva $677,26 \pm 84,46 \mu\text{s}$ para prover sua decisão, incluindo neste total de tempo, o tempo necessário à requisição das células da RoI pelo *Region Selector*. Dado que o tempo médio esperado para um evento ser processado pelo L2 é de 40 ms, o T2Calo cumpre muito bem com os requisitos de tempo necessários à operação *online*.

No lado direito da Figura 9.13, observa-se a distribuição, também em valores percentuais, do tempo gasto em cada etapa quando emprega-se o *Ringer* para a discriminação elétron / jato. Os valores absolutos de tempo estão apresentados na Tabela 9.3b. Nesta configuração de operação, apenas a parte de pré-processamento do T2Calo é executada. Por consequência, o *Region Selector* precisa ser acionado para prover as informações necessárias para a execução desta etapa. Uma vez que o T2Calo calcula suas 4 variáveis, além dos valores refinados de E_T , η e ϕ , tem início

a execução da parte do código específica ao *Ringer*.

O *Ringer*, tal como o T2Calo, também solicita ao *Region Selector* as informações referentes às células da RoI sendo analisada. Entretanto, uma parte desta informação já foi requisitada pelo T2Calo, de tal forma que o acesso, para o *Ringer* a estes dados é muito mais rápido, visto que se encontram em um *cache* local. Contudo, o tempo para a execução do *Region Selector* do *Ringer* ainda é consideravelmente alto. O motivo é que parte da informação requerida pelo *Ringer* (por exemplo, as células no pré-irradiador) não foram requisitadas pelo T2Calo, o que acaba produzindo uma nova solicitação aos ROS. Adicionalmente, a informação recebida do *Region Selector* já é organizada, pelo *Ringer*, em um dicionário, para que o algoritmo de anelamento encontre mais rapidamente as células pertencentes a uma dada camada. Estes 2 fatores, combinados, resultam em $\sim 36\%$ do tempo total do algoritmo sendo gasto nesta etapa.

Uma vez que a informação já se encontra disponível para análise, o processo é executado muito mais rapidamente. O algoritmo de anelamento, que consiste em achar a célula quente de cada camada, e construir os anéis para cada camada, representa apenas $\sim 8\%$ do tempo gasto ($98,56 \pm 16,48$). A normalização, neste caso, por energia total, leva apenas $2,59 \pm 1,49$ para ser executada¹. Por fim, a propagação dos anéis produzidos pela rede neural leva apenas $38,68 \pm 1,785 \mu\text{s}$ para ser feita², representando apenas $\sim 3\%$ do tempo total.

O tempo total gasto pelo T2Calo com o *Ringer* é de $1.419,83 \pm 0,46$. Isto significa que o *Ringer* introduz um *overhead* de, aproximadamente, 110%. Embora seja um incremento considerável, mesmo com este *overhead*, a cadeia completa de processamento para a identificação de elétrons no L2 (que inclui, além da análise por calorimetria, a análise do perfil da trajetória da partícula ao passar pelo detetor de traços) leva apenas $8,04 \pm 2,04$ ms para prover a decisão final do L2. Este valor representa apenas $\sim 20\%$ do tempo médio de 40 ms, por evento, especificado para o segundo nível de filtragem. Com isso, o sistema proposto encontra-se apto para ser empregado na operação *online* do L2, com a vantagem de que, como *Ringer*

¹A normalização sequencial, caso adotada, levaria $18,3037 \pm 6,64 \mu\text{s}$.

²O tempo de propagação, conforme apresentado na Seção 9.3.2 é de apenas $10,43 \pm 1,65$. Entretanto, à pedidos dos desenvolvedores do Athena, foi implementada uma funcionalidade para armazenar o valor de saída da rede neural no *Store Gate*, o que introduziu um *overhead* de $\sim 28\mu\text{s}$.

Tabela 9.4: Tempos (em microssegundos) para a criação dos anéis de cada camada.

Camada	<i>Region Selector</i>	Anelamento	Total
PS	7.12 ± 1.81	9.08 ± 4.39	16.20 ± 4.75
EM1	126.41 ± 30.86	31.09 ± 7.74	157.50 ± 31.82
EM2	79.42 ± 9.11	20.31 ± 2.08	99.72 ± 9.34
EM3	42.49 ± 5.63	11.11 ± 1.83	53.60 ± 5.92
HD1	$9,82 \pm 5,73$	7.97 ± 2.89	$17,79 \pm 6,42$
HD2	$8,28 \pm 5,51$	7.11 ± 2.70	$15,39 \pm 6,13$
HD3	$16,09 \pm 8,45$	7.12 ± 1.80	$23,21 \pm 8,64$

apresenta, para uma mesma probabilidade de detecção, uma taxa de rejeição de jatos $\sim 65\%$ menor do que o T2Calo empregado isoladamente, o tempo maior gasto por evento no L2 seria compensado pelo *Event Filter*, visto que menos falso-elétrons seriam propagados para o EF, que, por sua vez, gastará, em média 4 segundo com cada evento aprovado pelo L2.

Observando-se novamente, na Figura 9.13, a distribuição do tempo gasto pelo *Ringer*, nota-se, que, tal como o T2Calo, aproximadamente 76% do tempo do algoritmo é gasto com requisição de dados ao *Region Selector*. O algoritmo do *Region Selector* permite selecionar células pertencentes a uma dada camada. Desta forma, é possível, por exemplo, solicitar apenas as células provenientes da EM2³. A exceção são as células provenientes do barril do calorímetro hadrônico. Para este subdetetor, o *Region Selector* sempre retorna todas as células neste calorímetro, não fazendo nenhuma distinção a qual camada elas pertencem. Logo, mesmo que apenas uma camada hadrônica seja desejada, todas as células, de todas as camadas do barril do calorímetro hadrônico serão retornadas. No caso do barril estendido do calorímetro hadrônico, tal como para o calorímetro eletromagnético, é possível solicitar apenas a camada desejada.

Logo, um significativo tempo de processamento pode ser economizado se adotarmos a análise da relevância como um guia que dirá quais camadas devem ser, de

³As células retornadas, no entanto, podem ser provenientes tanto da tampa, bem como do barril.

fato, solicitadas ao *Region Selector*. É apresentado, na Tabela 9.4, o tempo gasto pelo *Region Selector* para retornar as células de cada uma das 7 camadas empregadas para a construção dos anéis. Nota-se que o tempo gasto para retornar as células de uma dada camada está correlacionado com a granularidade da mesma, pois, quanto mais fina é a granularidade, mais células serão retornadas. Para a HD3, o tempo ficou consideravelmente mais alto do que as outras camadas hadrônicas, pois o algoritmo de anelamento emprega 2 subdetetores (HADENCAP2 e HADENCAP3) para a composição dos anéis desta camada. Além disso, para as camadas hadrônicas, além do tempo gasto para pegar, na tampa do calorímetro hadrônico, as células específicas de uma dada camada, deve-se acrescentar o tempo necessário ($113, 15 \pm 77, 32 \mu s$) para pegar (sem distinção de camada) as células do barril do calorímetro hadrônico (este tempo não está sendo considerado na tabela). Entretanto, mesmo que as células de várias camadas sejam necessárias, este tempo adicional só será contado uma vez, visto que o *Region Selector* já retornará as células de todas as camadas. Por fim, a Tabela 9.4 também apresenta os valores de tempo gastos para se produzir os anéis de cada camada. Tal como o *Region Selector*, a tempo de processamento é proporcional ao número de células em cada camada.

Um significativo tempo de processamento pode ser economizado ao combinarmos a análise de tempo de cada camada com a análise da relevância, realizada no Capítulo 8. A análise da relevância, para as abordagens segmentadas, mostrou que, em vários casos, algumas das camadas poderiam ser descartadas, sem impactos significativos na eficiência de detecção. Por exemplo, a análise da relevância para a abordagem segmentada empregando componentes independentes compactadas por PCA retendo 97% da energia de cada camada mostrou que as camadas EM3, HD1, HD2 e HD3 são muito pouco relevantes, podendo, portanto, ser dispensadas sem grandes impactos na eficiência de classificação. Desta forma, ao eliminar-se estas 4 camadas, uma economia de tempo total de aproximadamente $223 \mu s$ seria obtida, o que significaria uma redução de quase 16% no tempo total do algoritmo seria obtida. Esta capacidade de redução do tempo de processamento, ao eliminar-se camadas pouco relevantes reforça, mais uma vez, os benefícios da abordagem segmentada.

Capítulo 10

Conclusões e Perspectivas

Sistemas de filtragem *online* representam, para a física experimental moderna, um recurso indispensável. Viu-se que, no caso do LHC e do ATLAS, um volume de 60 TBytes/s de informação será produzido, o que impossibilita o armazenamento de toda esta informação para análise *offline*.

O LHC e o ATLAS representam uma nova etapa da física experimental de altas energias. As colisões promovidas pelo LHC, obtidas a energias sem precedentes, permitirão um grande avanço na compreensão da estrutura da matéria. O ATLAS, com seus subdetetores finamente segmentados, é capaz de prover uma visão muito detalhada sobre os canais físicos produzidos pelas colisões do LHC. Para o ATLAS, a calorimetria joga um papel fundamental na análise de eventos provenientes de colisões de partículas, dado o seu curto tempo de resposta, e a identificação eficiente de partículas baseada na exploração do perfil de deposição de energia das mesmas.

Este trabalho apresentou um sistema de discriminação elétron / jato para operação *online* no segundo nível de filtragem do ATLAS, baseado em informação proveniente de calorimetria finamente segmentada. O segundo nível de filtragem, por lidar com eventos de sinal e ruído com características bastante semelhantes, trouxe um ótimo desafio para o processo de classificação. Entretanto, este trabalho pode se beneficiar do maior tempo oferecido pelo segundo nível para análise de cada evento para explorar técnicas de filtragem mais complexas.

A análise dos eventos realizada neste trabalho permitiu aprofundar o conhecimento sobre as características dos sinais recebidos pelo segundo nível de filtragem do ATLAS. Os dados simulados empregados neste trabalho foram apresentados, e um

estudo a respeito de suas características foi realizado. Este estudo permitiu aprofundar o conhecimento especialista sobre o problema, de forma que este conhecimento adquirido guiou o desenvolvimento do sistema classificador. Adicionalmente, o algoritmo de anelamento adotado neste trabalho também foi apresentado, e os anéis produzidos a partir destes dados de simulação foram estudados, mostrando que estes anéis foram capazes de representar o desenvolvimento do chuveiro de partículas de uma forma bastante compacta.

O pré-processamento estatístico dos anéis produzidos, por PCA e PCD, se mostrou um benéfico recurso para a extração, em um ambiente de alta dimensionalidade, de características relevantes à separação elétron / jato. Viu-se que a abordagem segmentada permitiu ponderar, de forma mais uniforme, a contribuição de cada camada para a decisão do sistema classificador, oferecendo resultados superiores de classificação para a maior parte das abordagens. Viu-se, também, que, em certas situações, a abordagem segmentada foi capaz de atingir custos computacionais menores, mesmo empregando um número maior de componentes do que a abordagem não segmentada. Por outro lado, a abordagem não segmentada, por observar as relações existentes entre as diversas camadas do sistema de calorimetria do ATLAS, permitiu isolar a informação discriminante em um número menor de componentes. Em todas as abordagens estudadas neste trabalho, os resultados de eficiência de classificação superaram por uma larga margem (pelo menos 50% menos falso alarme, para a mesma probabilidade de detecção), os resultados fornecidos pelo T2Calo, que, atualmente, é o algoritmo de referência para a separação elétron / jato no segundo nível de filtragem do ATLAS.

A utilização de técnicas não lineares de pré-processamento proporcionou resultados similares aos obtidos com técnicas lineares, porém empregando um número mais reduzido de componentes. A combinação da decorrelação não linear promovida pela ICA após projeção nos componentes principais de discriminação ofereceu, com apenas 8 componentes, um resultado superior ao obtido com a projeção nos 36 componentes principais mais energéticos.

No caso da análise de componentes independentes, viu-se que o número de fontes independentes é menor do que o número de sensores. A compactação dos anéis via PCA, realizada antes da extração das fontes independentes, permitiu estimar o

número correto de fontes independentes. Quando as fontes independentes foram estimadas a partir dos componentes principais de discriminação, foi possível selecionar as fontes independentes que são realmente úteis à classificação.

A análise da relevância, conforme apresentada, provou ser uma técnica eficiente para a eliminação inteligente de componentes, quando maior velocidade de processamento se faz necessária. A relevância também permitiu, no caso da análise de componentes independentes, atacar o problema do número de fontes ser menor do que o número de sensores, de tal forma que a RICA foi capaz de selecionar as fontes independentes relevantes à classificação, produzindo considerável redução no número de componentes empregados para a discriminação.

Discriminadores lineares se mostraram uma opção viável quando maior velocidade de execução é requerida. Mostrou-se, em muitos casos, que a substituição de uma rede neural por um classificador linear provê maiores ganhos de desempenho computacional do que a redução do número de variáveis fornecidas ao classificador, mantendo, ainda assim, uma eficiência de classificação muito superior ao T2Calo.

A análise com dados provenientes de raios cósmicos permitiu observar características reais de funcionamento do ATLAS. Situações nunca antes observadas com dados simulados foram estudadas. O teste da rede neural mostrou que a solução baseada em anéis topológicos proveu melhores índices de rejeição de raios cósmicos do que o T2Calo.

Para as análises realizadas com dados provenientes de colisão, a abordagem baseada em anéis e redes neurais proveu eficiências de identificação de elétrons aproximadamente 100% melhores dos que as obtidas pelo T2Calo, o que comprova, em ambiente real de operação, a superioridade do sistema proposto em relação ao T2Calo.

Neste trabalho, também foi descrito como o sistema desenvolvido foi implementado no Athena. Esta implementação permitiu que o sistema proposto fosse validado pelas mesmas ferramentas empregadas pelos desenvolvedores do Athena. Isto resultou num aumento da confiança da colaboração nos resultados obtidos com a pesquisa realizada. Adicionalmente, testes com dados experimentais só se tornaram possíveis uma vez que o sistema proposto encontra-se inserido no Athena.

Após implementação inicial no Athena, otimizações substanciais foram realiza-

das ao longo deste trabalho. A complexidade do algoritmo foi substancialmente reduzida, trazendo benefícios à depuração e a inclusão de novas funcionalidades. Ao ser integrado ao T2Calo, a redundância de certos processamentos foi eliminada, colaborando para a otimização geral da cadeia de processamento do segundo nível de filtragem. Como ganho adicional, esta integração com o T2Calo sinaliza que os desenvolvedores do Athena confiam nos resultados proporcionados pelas pesquisas conduzidas na UFRJ.

A análise de tempo, após as otimizações do algoritmo no Athena, mostrou que o sistema proposto aproximadamente dobrou o tempo gasto para prover a decisão a respeito da classe da partícula incidente, em relação à utilização do T2Calo isoladamente. Embora seja um aumento considerável, viu-se que, em valores absolutos, o sistema proposto fez com que o tempo de processamento de toda a cadeia de algoritmos para o canal elétron / jato ficasse em, aproximadamente, 8 ms, o que fica muito abaixo dos 40 ms de tempo médio, por evento, especificado para o segundo nível de filtragem. Adicionalmente, viu-se que este tempo pode ser reduzido eliminando-se camadas contendo anéis considerados irrelevantes pela análise da relevância. De qualquer forma, foi comprovada a viabilidade da pesquisa realizada para utilização *online*.

Para lidar com a alta complexidade e o elevado grau de configurabilidade proporcionado pelo sistema de filtragem do ATLAS, foi desenvolvido um sistema de apoio que visa auxiliar usuários com diferentes níveis de familiaridade com o sistema de filtragem do ATLAS a configurar este complexo ambiente para as suas necessidades. Este sistema permitiu que usuários descrevessem, de forma bastante intuitiva, como gostariam de configurar o sistema de filtragem para uma dada operação. No caso deste trabalho, o sistema desenvolvido foi de grande importância para que a pesquisa desenvolvida pudesse ser validada no ambiente real de operação do ATLAS.

Os resultados superiores de eficiência de classificação obtidos neste trabalho, com a conseqüente implementação e validação destes no Athena, contribuíram de forma muito benéfica para o estreitamento das relações entre a UFRJ e o sistema de filtragem do ATLAS. Com o início da operação do LHC, espera-se que novos dados experimentais em alta luminosidade estejam em breve disponíveis. A validação do sistema proposto neste trabalho com dados experimentais de alta luminosidade

proporcionará uma excelente oportunidade, junto a colaboração ATLAS, para que o sistema de classificação elétron / jato desenvolvido neste trabalho possa se tornar, apoiado pelo T2Calo, o algoritmo de referência para a identificação de elétrons no segundo nível de filtragem do ATLAS.

10.1 Perspectivas

A normalização sequencial, diferentemente do ocorrido em outros trabalhos semelhantes, não produziu os melhores resultados, quando comparada com outras técnicas de normalização por energia do evento. Entretanto, baseado no conhecimento especialista do problema, tem-se confiança de que esta deve ser a normalização adotada, faltando apenas um estudo mais profundo para se determinar os seus limiares ótimos. Desta forma, propõe-se, como atividade futura, otimizar esta normalização para dados filtrados pelo corte $e15i$ do primeiro nível de filtragem.

Neste trabalho, considerou-se que a mistura de fontes independentes é linear. Entretanto, pequenas não linearidades existem no sistema de calorimetria do ATLAS, resultando em uma combinação não linear da informação proveniente destas fontes independentes. Conseqüentemente, a análise de componentes independentes não lineares pode ser empregada para isolar canais independentes, mesmo quando misturados de maneira não linear durante a interação com o sistema de calorimetria do ATLAS. Adicionalmente, a técnica de análise de componentes independentes ruidosas também poderá ser explorada para que o modelo de ICA leve em consideração o ruído existente no processo. Por fim, a classificação pode ser realizada através da utilização de Máquinas de Vetores de Suporte.

O sistema desenvolvido neste trabalho tem foco na operação *online*. Contudo, os excelentes resultados de eficiência de classificação obtidos o torna apto a integrar o conjunto de algoritmos *offline* do ATLAS. Como trabalho futuro, uma versão do sistema desenvolvido neste trabalho pode ser integrada ao ambiente *offline* do sistema de filtragem. Adicionalmente, o algoritmo desenvolvido é relativamente simples de se implementar, de forma que pode ser facilmente adaptado para outros experimentos.

No Athena, existe uma proposta de se empregar uma janela deslizante para

encontrar múltiplos *clusters* de eventos dentro de uma RoI. Consequentemente, um projeto futuro seria adaptar o sistema desenvolvido para operar com os *clusters* encontrados por este algoritmo baseado em janelas deslizantes.

O algoritmo de anelamento, combinado com redes neurais, não precisa ser exclusivo do canal elétron / jato. A mesma abordagem pode ser empregada em outros canais físicos de interesse. Por exemplo, o sistema desenvolvido pode ser empregado para a identificação de *lepton-jets*, que é um canal relevante para pesquisas relacionadas à matéria escura.

O algoritmo de anelamento, para cada camada, requisita, ao *Region Selector*, as células contidas em uma região de $0,4 \times 0,4$ em $\eta \times \phi$. Entretanto, de acordo com as análises de relevância realizadas neste trabalho, para algumas camadas, as dimensões desta região podem estar exageradas. Com isso, mais células do que o necessário são requisitadas, o que, não só aumenta o tempo do *Region Selector*, bem como o tempo do anelador. Com isso, propõe-se um estudo para que a região, em $\eta \times \phi$, seja distinta para cada camada, baseada no número de anéis a serem produzidos em cada camada.

Uma vez o LHC operando à máxima luminosidade, dados experimentais poderão ser obtidos em grande quantidade. Desta forma, propõe-se a aquisição de novos dados, em alta luminosidade, para que o forte efeito de empilhamento existente nesta situação possa servir de teste para verificar o impacto gerado pela análise de componentes independentes na remoção deste ruído proveniente do empilhamento de partículas.

Referências Bibliográficas

- [1] PERKINS, D. H., *Introduction to High Energy Physics*. 4^a ed. Cambridge University Press, 2000.
- [2] DAWSON, S., *Introduction to the Physics of Higgs Bosons*, Notas de Aula BNL-61012, Brookhaven National Laboratory, outubro 1994.
- [3] EVANS, L., BRYANT, P., “LHC Machine”, *Journal of Instrumentation*, v. 1, n. 2008 JINST 3 S08001, agosto 2008.
- [4] “The Large Hadron Collider Experiment”, <http://public.web.cern.ch/Public/en/LHC/LHC-en.html>, dezembro 2009.
- [5] CHATRCHYAN, S., ADAM, W., BAUER, T., et al., “The CMS experiment at the CERN LHC”, *Journal of Instrumentation*, v. 1, n. 2008 JINST 3 S08004, agosto 2008.
- [6] GRIFFITHS, D., *Introduction to Elementary Particles*. John Wiley & Sons, 1987.
- [7] ALVES JUNIOR, A. A., ANDRADE FILHO, L. M., BARBOSA, A. F., et al., “The LHCb Detector at the LHC”, *Journal of Instrumentation*, v. 1, n. 2008 JINST 3 S08005, agosto 2008.
- [8] AAMODT, K., QUINTANA, A. A., ACHENBACH, R., et al., “The ALICE experiment at the CERN LHC”, *Journal of Instrumentation*, v. 1, n. 2008 JINST 3 S08002, agosto 2008.
- [9] ANELLI, G., G. ANTICHEV, ASPELL, P., et al., “The TOTEM Experiment at the CERN Large Hadron Collider”, *Journal of Instrumentation*, v. 1, n. 2008 JINST 3 S08007, agosto 2008.

- [10] “CERN Document Server”, <http://cdsweb.cern.ch>, junho 2009.
- [11] AAD, G., ABAT, E., ABDALLAH, J., et al., “The ATLAS Experiment at the CERN Large Hadron Collider”, *Journal of Instrumentation*, v. 1, n. 2008 JINST 3 S08003, agosto 2008.
- [12] “The ATLAS Experiment”, <http://atlas.ch>, fevereiro 2008.
- [13] WIGMANS, R., *Calorimetry: Energy Measurement In Particle Physics*. Oxford, 2000.
- [14] CRAWFORD, H. J., “Particle identification in a liquid argon calorimeter”, *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, v. 327, n. 1, pp. 199 – 202, 1993.
- [15] KNOLL, G. F., *Radiation Detection and Measurement*. 2nd ed. John Wiley & Sons, 1989.
- [16] JELLEY, J. V., “Čerenkov Radiation and its Applications”, *British Journal of Applied Physics*, v. 6, n. 7, pp. 227–232, 1955.
- [17] ACOSTA, D., BUONTEMPO, S., CALÔBA, L., et al., “Lateral Shower Profiles in a Lead/Scintillating Fiber Calorimeter”, *Nuclear Instruments and Methods in Physics Research*, v. 316, n. 2, pp. 184–201, junho 1992.
- [18] KENYON, I., “The Discovery of the Intermediate Vector Bosons”, *European Journal of Physics*, v. 6, n. 1, pp. 41–55, 1985.
- [19] BAUMGART, R., GRUPENA, C., MEYER, H.-J., et al., “Electron-Pion Discrimination in an Iron/Streamer Tube Calorimeter up to 100 GeV”, *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, v. 272, n. 3, pp. 722–726, 1988.
- [20] BADIÉ, J., BOUHEMAID, N., BUONTEMPO, S., et al., “Test Results of a Fully Projective Lead/Scintillating-Fiber Calorimeter”, *Nuclear Instruments and Methods in Physics Research*, v. 337, n. 2, pp. 326–341, janeiro 1994.

- [21] COBB, J. H., “A Large Liquid-Argon Shower Detector for an ISR Experiment”, *Nuclear Instruments and Methods*, v. 158, n. 1, pp. 93–110, 1979.
- [22] ACOSTA, D., BUONTEMPO, S., CALÔBA, L., et al., “Localizing Particles Showering in a Spaghetti Calorimeter”, *Nuclear Instruments and Methods in Physics Research*, v. 305, n. 1, pp. 55–70, julho 1991.
- [23] ALBROW, M., AOTA, S., APOLLINARI, G., et al., “A Preshower Detector for the CDF Plug Upgrade: Test Beam Results”, *Nuclear Instruments and Methods in Physics Research*, v. A431, n. 1, pp. 104–111, julho 1999.
- [24] “The ZEUS Experiment”, <http://www-zeus.desy.de/>, outubro 2009.
- [25] “The HERA-B Collider”, <http://www-hera-b.desy.de/>, outubro 2009.
- [26] ATLAS COLLABORATION, *Calorimeter Performance Technical Design Report*, Relatório Técnico CERN/LHCC 96-40, CERN, janeiro 1997.
- [27] OKAWA, H., “Commissioning of the ATLAS Tile Calorimeter with Cosmic Ray and Single Beam Data”. In: *Nuclear Science Symposium Conference Record*, pp. 3394–3399, Dresden, Alemanha, outubro 2008.
- [28] ATLAS COLLABORATION, *Data Preparation for the ATLAS High Level Trigger Calorimeter Algorithms*, Relatório técnico, CERN, fevereiro 2008.
- [29] WATTS, G., “Review of triggering”. In: *Nuclear Science Symposium Conference Record, 2003 IEEE*, v. 1, pp. 282–287, Portland, USA, outubro 2003.
- [30] LINDENSTRUTH, V., KISEL, I., “Overview of Trigger Systems”, *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, v. 535, n. 1-2, pp. 48–56, 2004.
- [31] ACKENHUSEN, J. G., *Real-Time Signal Processing*. Prentice Hall, 1999.
- [32] JOHN, M., SMITH, S., *Application-Specific Integrated Circuits*. Addison-Wesley Professional, 1997.

- [33] BROWN, S., VRANESIC, Z., *Fundamentals of Digital Logic with VHDL Design*. McGraw-Hill, 2000.
- [34] “The CDF Experiment”, <http://www-cdf.fnal.gov/>, dezembro 2009.
- [35] “The DØ Experiment”, <http://www-d0.fnal.gov/>, dezembro 2009.
- [36] 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.
- [37] DENBY, B., GARDA, P., GRANADO, B., et al., “Fast Triggering in High Energy Physics Experiments Using Hardware Neural Networks”, *IEEE Transactions on Neural Networks*, v. 14, n. 5, pp. 1–17, setembro 2003.
- [38] NICHOLLS, T., CHARLET, M., COUGHLAN, J., et al., “Concept, Design and Performance of the Second Level Triggers of the H1 Detector”, *IEEE Transactions on Nuclear Science*, v. 45, n. 3, pp. 810–816, junho 1998.
- [39] KÖHNE, J. K., FENT, J., FRÖCHTENICHT, W., et al., “Realization of a Second Level Neural Network Trigger for the H1 Experiment at HERA”, *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, v. 389, n. 1-2, pp. 128 – 133, 1997.
- [40] KIESLING, C., “The H1 Neural Network Trigger”. In: *Proceedings of the International Joint Conference on Neural Networks*, v. 1, pp. 393–398, Portland, USA, julho 2003.
- [41] SALERNO, R., “Electron reconstruction in CMS at the LHC”, *Nuclear Physics B - Proceedings Supplements*, v. 172, n. 257-259, outubro 2007.
- [42] THE TRIDAS PROJECT, *Data Acquisition and High-Level Trigger*, Relatório Técnico CERN/LHCC 02-26, CMS Collaboration, dezembro 2002.
- [43] BAINES, J., GEORGE, S., GONZALEZ, S., et al., *Identification of High p_T Electrons by the Second Level Trigger of ATLAS*, Relatório Técnico ATL-DAQ-2000-003, The ATLAS Collaboration, 2000.

- [44] DOS ANJOS, A. R., *Sistema Online de Filtragem em um Ambiente com Alta Taxa de Eventos*, Tese de doutorado COPPE/PEE, Universidade Federal do Rio de Janeiro, dezembro 2006.
- [45] LIMA JÚNIOR, H. P., *Monitoração Online e Processamento Distribuído para um Ambiente com Alta Taxa de Eventos e Fina Segmentação*, Tese de doutorado COPPE/PEE, UFRJ, outubro 2006.
- [46] JOLLIFFE, I. T., *Principal Component Analysis*. 2^a ed. Springer, 2002.
- [47] SHANMUGAN, K. S., BREIPOHL, A. M., *Random Signals - Detection, Estimation and Data Analysis*. John Wiley & Sons, 1988.
- [48] BHAT, P. C., GILMARTIN, R., PROSPER, H. B., “Strategy for Discovering a Low-Mass Higgs Boson at the Fermilab Tevatron”, *Physical Review D*, v. 62, n. 7, pp. 074022, setembro 2000.
- [49] THE DELPHI COLLABORATION, “Measurement of the W-Pair Production Cross-Section and W Branching Ratios in e^+e^- Collisions at $\sqrt{s} = 161 - 209$ GeV”, *The European Physical Journal C - Particles and Fields*, v. 34, n. 2, pp. 127–144, maio 2004.
- [50] WOLTER, M., THE ATLAS COLLABORATION, “Tau Identification Using Multivariate Techniques in ATLAS”, *Proceedings of Science*, v. 1, n. PoS(ACAT08)080, pp. 1–6, 2008.
- [51] ATLAS LEVEL-1 TRIGGER GROUP, *ATLAS Level-1 Trigger Technical Design Report*, Relatório técnico, CERN, ATLAS TDR-12, agosto 1998.
- [52] ACHENBACH, R., ADRAGNA, P., ANDREI, V., et al., “The ATLAS Level-1 Calorimeter Trigger”, *Journal of Instrumentation*, v. 3, n. 03, pp. P03001, 2008.
- [53] CERQUEIRA, A. S., SEIXAS, J. M., CALÔBA, L. P., “Analog System for Building the First-Level Triggering Signal Provided by the Hadronic Calorimeter of ATLAS Detector”, *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, v. 570, n. 1, pp. 117–125, 2007.

- [54] BUCHANAN, N. J., CHEN, L., GINGRICH, D. M., et al., “Design and Implementation of the Front End Board for the Readout of the ATLAS Liquid Argon Calorimeters”, *Journal of Instrumentation*, v. 3, n. 03, pp. P03004, 2008.
- [55] ATLAS GROUP, *ATLAS Muon Spectrometer Technical Design Report*, Tech. rep., CERN, maio 1997.
- [56] ATLAS GROUP, *ATLAS Trigger Performance Status Report*, Tech. rep., CERN, junho 1998.
- [57] RIU, I., ABOLINS, M., ADRAGNA, P., et al., “Integration of the Trigger and Data Acquisition Systems in ATLAS”, *IEEE Transactions on Nuclear Science*, v. 55, n. 1, pp. 106–112, fevereiro 2008.
- [58] DOS ANJOS, A., ABOLINS, M., ARMSTRONG, S., et al., “The Second Level Trigger of the ATLAS Experiment at CERN’s LHC”, *IEEE Transactions on Nuclear Science*, v. 51, n. 3, pp. 909–914, junho 2004.
- [59] SCHILDT, H., *C++: The Complete Reference*. 4^a ed. McGraw-Hill, 2003.
- [60] TANENBAUM, A. S., *Modern Operating Systems*. 2^a ed. Prentice Hall, 2001.
- [61] ATLAS HLT/DAQ/DCS GROUP, *ATLAS: High-Level Trigger Data Acquisition and Controls*, Relatório técnico, CERN, ATLAS TDR-016, outubro 2003.
- [62] VANDELLI, W., ABOLINS, M., BATTAGLIA, A., et al., “The ATLAS Event Builder”. In: *Nuclear Science Symposium Conference Record*, v. 1, pp. 120–126, Hawaii, USA, 2007.
- [63] VAN DER BIJ, H. C., MCLAREN, R. A., BOYLE, O., et al., “S-LINK, a Data Link Interface Specification for the LHC Era”, *IEEE Transactions on Nuclear Science*, v. 44, pp. 398–402, junho 1997.
- [64] CORTI, G., CATTANEO, M., CHARPENTIER, P., et al., “Software for the LHCb experiment”, *IEEE Transactions on Nuclear Science*, v. 53, n. 3, pp. 1323–1328, junho 2006.
- [65] ATLAS Collaboration, *Athena Developer Guide*, 2^a ed., agosto 2001.

- [66] “ROOT: an Object-Oriented Data Analysis Framework”, <http://root.cern.ch>, outubro 2009.
- [67] BEE, C., FRANCIS, D., MAPELLI, L., et al., *The Raw Event Format in the ATLAS Trigger & DAQ*, Relatório Técnico ATL-D-ES-0019, ATLAS Collaboration, abril 2005.
- [68] ACHENBACH, R., ADRAGNA, P., AHARROUCHE, M., et al., “First Data with the ATLAS Level-1 Calorimeter Trigger”. In: *IEEE Nuclear Science Symposium Conference Record*, pp. 1851–1858, Dresden, Germany, outubro 2008.
- [69] JONES, R., MAPELLI, L., RYABOV, Y., et al., “The OKS Persistent In-Memory Object Manager”, *IEEE Transactions on Nuclear Science*, v. 45, n. 4, pp. 1958–1964, agosto 1998.
- [70] SIMÕES, J. A., DOBSON, M., KAZAROV, A., et al., “The ATLAS DAQ System Online Configurations Database Service Challenge”, *Journal of Physics: Conference Series*, v. 119, n. 022004, pp. 1–11, 2008.
- [71] KEOGH, J., GIANNINI, M., *OOP Demystified*. McGraw-Hill, 2004.
- [72] HAROLD, E. R., MEANS, W. S., *XML in a Nutshell*. 3^a ed. O’Reilly, 2004.
- [73] “The Python Programming Language”, <http://www.python.org>, julho 2007.
- [74] “C++/Python Interfacing”, <http://www.language-binding.net/pyplusplus/pyplusplus.html>, março 2008.
- [75] ALEXANDROV, I., AMORIM, A., BADESCU, E., et al., “Online Software for the ATLAS Test Beam Data Acquisition System”, *IEEE Transactions on Nuclear Science*, v. 51, n. 3, pp. 578–584, junho 2004.
- [76] UNEL, G., ABOLINS, M., ADRAGNA, P., et al., “Studies with the ATLAS Trigger and Data Acquisition Pre-Series Setup”. In: *Proceeding in Computing in High Energy Physics (CHEP)*, pp. 922–926, Mumbai, Índia, fevereiro 2006.

- [77] BRUN, R., RADEMAKERS, F., “ROOT - An Object Oriented Data Analysis Framework”, *Nuclear Instruments and Methods in Physics Research*, v. 389, n. 1-2, pp. 81–86, abril 1997.
- [78] THE ATLAS COLLABORATION, *Expected Performance of the ATLAS Experiment: Detector, Trigger and Physics*, Relatório técnico, CERN, dezembro 2008.
- [79] COVER, T. M., THOMAS, J. A., *Elements of Information Theory*. John Wiley & Sons, 1991.
- [80] JOE, H., “Relative Entropy Measures of Multivariate Dependence”, *Journal of the American Statistical Association*, v. 84, n. 405, pp. 157–164, março 1989.
- [81] VAN TREES, H. L., *Detection, Estimation, and Modulation Theory*. v. 1. John Wiley & Sons, 2001.
- [82] THE ATLAS COLLABORATION, *The ATLAS Trigger for Early Running*, Nota, CERN, 2009.
- [83] HAYKIN, S., *Neural Networks and Learning Machines*. 3rd ed. Prentice Hall, 2008.
- [84] 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.
- [85] RIEDMILLER, M., BRAUN, H., “A Direct Adaptive Method for Faster Backpropagation Learning: The RPROP Algorithm”. In: *Proceedings of the IEEE International Conference on Neural Networks*, pp. 586–591, San Francisco, USA, 1993.
- [86] JACKSON, J. E., *A User’s Guide to Principal Components*. John Wiley & Sons, 1991.

- [87] HYVÄRINEN, A., KARHUNEN, J., OJA, E., *Independent Component Analysis*. John Wiley & Sons, 2001.
- [88] HYVÄRINEN, A., SÄRELÄ, J., VIGÁRIO, R., “Spikes and Bumps: Artefacts Generated by Independent Component Analysis with Insufficient Sample Size”. In: *Proceedings of the International Workshop on Independent Component Analysis and Signal Separation*, pp. 425–429, Aussois, France, 1999.
- [89] GRUBER, A., MÖCK, J., FRÖCHTENICHT, J., et al., “Performance of Back-propagation Networks in the Second Level Trigger of the H1-Experiment”, *New Computing Techniques in Physics Research*, 1994.
- [90] DUDA, R. O., HART, P. E., STORK, D. G., *Pattern Classification*. 2nd ed. Wiley-Interscience, 2004.
- [91] GAISSER, T. K., *Cosmic Rays and Particle Physics*. Cambridge University Press, 1990.
- [92] DE ANDRADE FILHO, L. M., *Detecção e Reconstrução de Raios Cósricos Usando Calorimetria de Altas Energias*, Tese de doutorado COPPE/PEE, Universidade Federal do Rio de Janeiro, 2009.
- [93] STRANG, G., *Introduction to Linear Algebra*. 4^a ed. Wellesley Cmbridge Press, 2009.
- [94] CALÔBA, L. P., SEIXAS, J. M., PEREIRA, F. S., “Neural Discriminating Analysis For A Second Level Trigger System”. In: *Computing in High Energy Physics*, pp. 870–874, Rio de Janeiro, Brazil, 1995.
- [95] CHOI, S., CICHOCKI, A., PARK, H., et al., “Blind Source Separation and Independent Component Analysis - A Review”, *Neural Information Processing - Letters and Reviews*, v. 6, n. 1, pp. 1–57, 2005.
- [96] MOURA, N. N., SIMAS FILHO, E. F., SEIXAS, J. M., “Advances in Sonar Signal Processing”, In: *Advances in Sonar Signal Processing*, chap. Independent Component Analysis for Passive Sonar Signal Processing, pp. 91–110, InTech: Vienna, Áustria, 2009.

- [97] SYSKIND, M., WANG, D. L., LARSEN, J., et al., “Separating Underdetermined Convolutional Speech Mixtures”. In: *Independent Component Analysis And Signal Separation, 8th International Conference, Lecture Notes In Computer Science*, pp. 674–681, Springer: Charleston, USA, março 2006.
- [98] NATORA, M., FRANKE, F., MUNK, M., et al., “BSS of Sparse Overcomplete Mixtures and Application to Neural Recordings”. In: *Independent Component Analysis And Signal Separation, 8th International Conference, Lecture Notes In Computer Science*, pp. 459–467, Springer: Parati, Rio de Janeiro, março 2009.
- [99] SIMAS FILHO, E. F., SEIXAS, J. M., CALOBA, L. P., “Optimized Calorimeter Signal Compaction for an Independent Component based ATLAS Electron/Jet Second-Level Trigger”, *Proceedings of Science - PoS*, v. ACAT08, n. 102, pp. 1–10, 2009.
- [100] PAPOULIS, A., PILLAI, S. U., *Probability, Random Variables, and Stochastic Processes*. 4th ed. McGraw-Hill, 2002.
- [101] CICHOCKI, A., AMARI, S., *Adaptive Blind Signal and Image Processing*. Willey, 2002.
- [102] CICHOCKI, A., UNBEHAUEN, R., “Robust Neural Networks with On-Line Learning for Blind Identification and Blind Separation of Sources”, *IEEE Transactions on Circuits and Systems*, v. 43, n. 11, pp. 894–906, novembro 1996.
- [103] MCCLAVE, J. T., SINCICH, T., MENDENHALL, W., *Statistics*. 11^a ed. Prentice Hall, 2008.
- [104] MACKAY, D. J. C., *Information Theory, Inference and Learning Algorithms*. Cambridge University Press, 2002.
- [105] SHANNON, C. E., “A Mathematical Theory of Communication”, *The Bell System Technical Journal*, pp. 379–423, julho 1948.
- [106] HAYKIN, S., *Communication Systems*. 3^a ed. John Wiley & Sons, 1994.

- [107] MURILLO-FUENTES, J., BOLOIX-TORTOSA, R., HORNILLO-MELLADO, S., et al., “Independent Component Analysis Based on Marginal Entropy Approximations”. In: *Proceedings of the World Automation Congress*, v. 16, n. 16, pp. 433–438, Sevilla, Spain, junho 2004.
- [108] CARDOSO, J.-F., SOULOUMIAC, A., “Blind Beamforming for Non-gaussian Signals”, *IEE Proceedings-F*, v. 140, n. 6, pp. 362–370, novembro 1993.
- [109] HYVARINEN, A., “Fast and Robust Fixed-Point Algorithms for Independent Component Analysis”, *IEEE Transactions on Neural Networks*, v. 10, n. 3, pp. 626–634, 1999.
- [110] HYVARINEN, A., OJA, “Independent Component Analysis: Algorithms and Applications”, *Neural Networks*, v. 13, n. 4-5, pp. 411–430, 2000.
- [111] MICHAL, A. D., *Matrix and Tensor Calculus With Applications to Mechanics, Elasticity and Aeronautics*. 1^a ed. Dover, 2008.
- [112] CARDOSO, J.-F., “High-Order Contrasts for Independent Component Analysis”, *Neural Computation*, v. 11, n. 1, pp. 157–192, 1999.

Apêndice A

Pré-Processamento Estocástico de Sinais

As técnicas de pré-processamento apresentadas neste capítulo podem ser empregadas em uma vasta área de aplicações. O emprego de tais técnicas permite, em problema de dimensão muito elevada, por exemplo, isolar a informação relevante à aplicação sendo desenvolvida (estimadores, classificadores, etc.), facilitando a análise, bem como a implementação da solução. Cada uma das técnicas a seguir apresenta um foco específico de análise (independência, discriminação, etc.), mas, para a solução de problemas práticos, a combinação de uma ou mais técnicas aqui descritas não é incomum.

A.1 Análise de Componentes Principais

Análise de componentes principais (PCA) [46] é uma técnica de processamento estocástico de sinais que visa obter uma nova representação para os sinais de entrada, de tal forma que a energia do processo esteja concentrada no menor número possível de componentes.

Usando estatística de segunda ordem, a PCA busca por um espaço onde a projeção $\mathbf{v} = \mathbf{W}\mathbf{x}$, de um vetor aleatório $\mathbf{x} \in \mathbb{R}^N$ de média nula, apresentará seus componentes descorrelacionados (isto é, compondo uma base ortonormal) e possuindo máxima variância.

O primeiro vetor de base \mathbf{w}_1 de componentes principais pode ser computado

através da maximização de

$$J_1^{PCA}(\mathbf{w}_1) = E\{\mathbf{v}^2\} = E\{(\mathbf{w}_1\mathbf{x})^2\} = \mathbf{w}_1^T \mathbf{C}_x \mathbf{w}_1 \quad (\text{A.1})$$

onde \mathbf{C}_x é a matriz de covariância de \mathbf{x} e $\|\mathbf{w}_1\| = 1$.

Em muitos casos práticos, a extração de componentes principais é realizada através da decomposição singular (*Eigenvalue Decomposition* - EVD) [93] da matriz \mathbf{C}_x . Isto implica resolver o seguinte sistema de equações

$$\mathbf{E}^T \mathbf{R} \mathbf{E} = \mathbf{\Lambda} \quad (\text{A.2})$$

$$|\mathbf{E} - \lambda \mathbf{I}| = 0 \quad (\text{A.3})$$

onde \mathbf{E} é a matriz ortonormal contendo os autovetores de \mathbf{C}_x , $\mathbf{\Lambda}$ é a matriz diagonal onde os elementos $\lambda_1, \lambda_2, \dots, \lambda_N$ são os autovalores de \mathbf{C}_x , e \mathbf{I} é a matriz identidade. Uma vez que os autovetores foram extraídos, estes são ordenados de maneira decrescente pelos seus respectivos autovalores. Neste caso, como \mathbf{x} tem média nula, os autovalores fornecem a quantidade de energia retida por cada componente. Como resultado, ao serem descartados os componentes menos energéticos, a dimensão do espaço de análise pode ser reduzida de maneira otimizada, no que tange o erro médio quadrático.

A análise de componentes principais, por ser um método baseado em estatística de segunda ordem, é ótima para processos gaussianos, visto que o conhecimento da média e da variância é suficiente para se definir completamente uma densidade de probabilidade gaussiana (todos os momentos superiores ao segundo são nulos). Conseqüentemente, métodos de análise baseados em estatística de ordem superior não são capazes de obter nenhuma informação adicional sobre processos gaussianos, quando comparados à análise de componentes principais.

A.1.1 Branqueamento

Um vetor \mathbf{z} de variáveis aleatórias de media nula é dito *branco* se suas componentes forem descorrelacionadas e possuírem variância unitária [87]. Isto implica que a matriz de covariância de \mathbf{z} é igual à matriz identidade. O processo de branqueamento

também é referido como esferização, e é uma operação ligeiramente mais forte do que a simples decorrelação.

A matriz de transformação linear \mathbf{V} que conduzirá ao branqueamento das variáveis aleatórias de um vetor aleatório \mathbf{x} de média nula será dada por

$$\mathbf{V} = \mathbf{\Lambda}^{-1/2} \mathbf{E}^T \quad (\text{A.4})$$

onde \mathbf{E} é a matriz onde cada coluna é um autovetor (com norma unitária) da matriz de covariância $\mathbf{C}_{\mathbf{x}}$ de \mathbf{x} , e $\mathbf{\Lambda}$ é a matriz diagonal com os autovalores de $\mathbf{C}_{\mathbf{x}}$.

A.2 Componentes Principais de Discriminação

Em problemas de reconhecimento de padrões, PCA é comumente empregada no pré-processamento da informação de entrada, antes da mesma ser fornecida para o sistema classificador. O objetivo, nestes casos, é compactar o sinal de entrada, descartando componentes minoritários (menos energéticos). Entretanto, nem sempre os componentes mais energéticos são os que, de fato, carregam a informação útil à classificação. Este problema fica claro no exemplo apresentado na Figura A.1. Neste exemplo, um vetor $\mathbf{x} \in \mathbb{R}^2$ de média nula, contém K realizações de sinais pertencentes à duas classes distintas (A e B). Ao projetar-se \mathbf{x} em seus componentes principais, observa-se que o primeiro componente retém, isoladamente, cerca de 96% da variância do sinal. Entretanto, nenhuma distinção entre as classes pode ser feita através deste componente. Por outro lado, o segundo componente, embora contribua com apenas $\sim 4\%$ da energia do processo, permite distinguir eficientemente os limites entre as duas classes.

A análise de componentes principais de discriminação (PCD) [94], ao invés de procurar direções que maximizem a variância de um sinal de entrada, busca as direções que maximizem a distinção entre classes diferentes de sinais. Tomando-se novamente o exemplo apresentado na Figura A.1, a Figura A.2 apresenta a projeção de \mathbf{x} em seus componentes principais de discriminação. Como pode ser notado, a análise por PCD ordenou corretamente os vetores de base, de acordo com o seu potencial de discriminação, ignorando a quantidade de energia retida por cada componente.

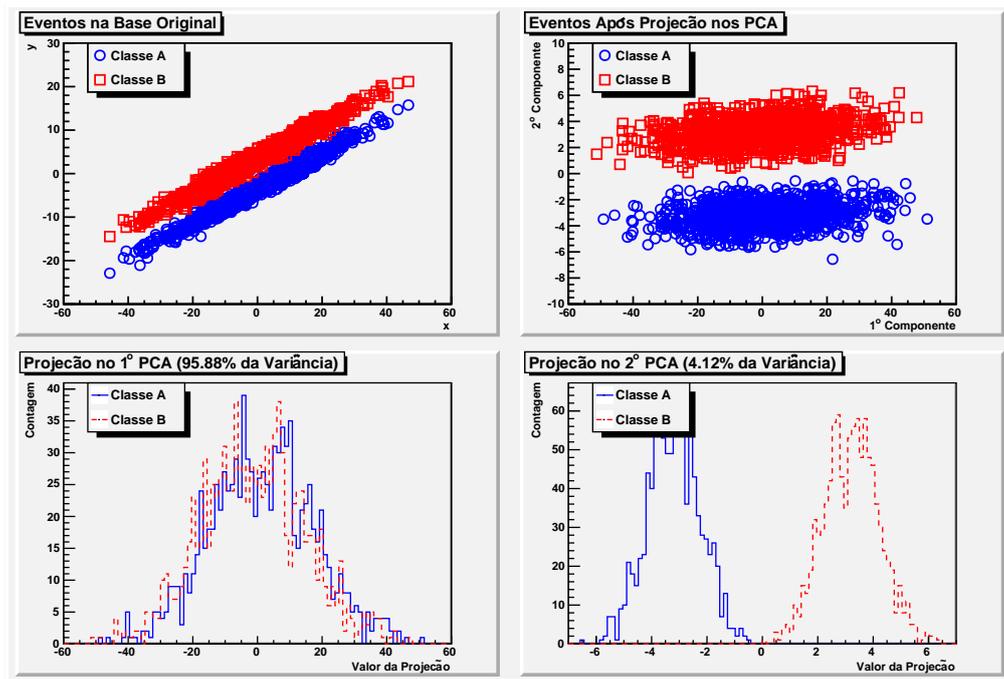


Figura A.1: Exemplo onde o componente principal mais energético não fornece nenhuma informação útil para a distinção entre classes.

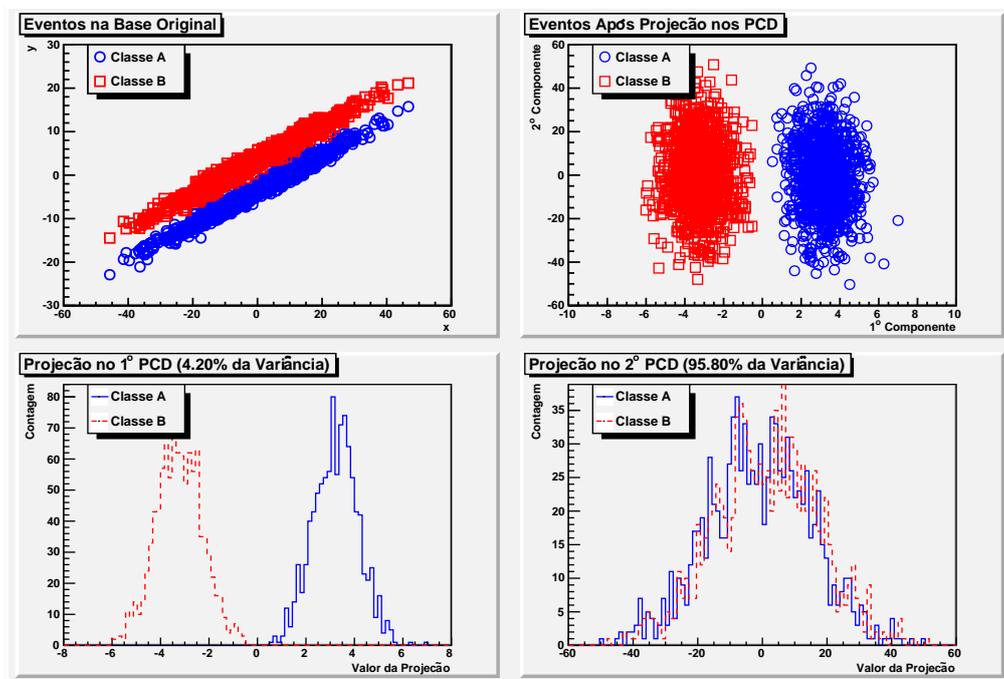


Figura A.2: Exemplo de como a PCD fornece direções úteis à distinção entre classes.

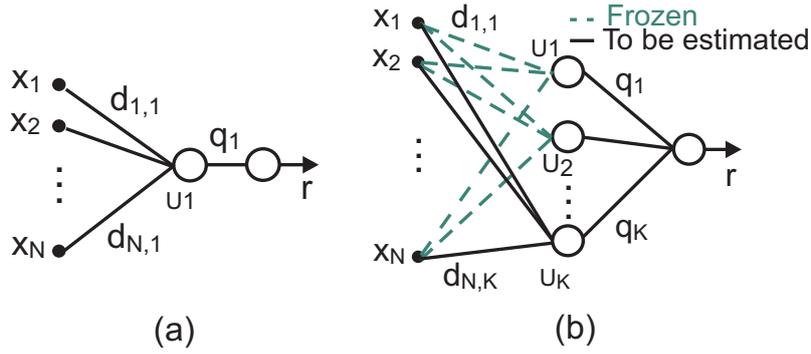


Figura A.3: Esquema de extração dos componentes principais de discriminação.

A extração dos componentes principais de discriminação é realizada através de redes neurais artificiais (vide Figura A.3). Considerando-se um vetor aleatório $\mathbf{x} \in \mathbb{R}^N$, uma rede neural multicamada com função de ativação não linear, contendo um único neurônio na camada escondida, pode extrair o primeiro componente. Quando o processo de treinamento se encerra, as sinapses de entrada do neurônio na camada escondida contêm a direção do primeiro componente principal de discriminação. Em seguida, estas sinapses são congeladas, e um novo neurônio é adicionado à camada escondida. O treinamento é, então, feito, fornecendo nas sinapses do segundo neurônio da camada escondida, o segundo componente. O processo continua até o ponto onde a adição de novos componentes não resulta em melhora na eficiência de classificação.

A.2.1 Componentes Principais Ortogonais de Discriminação

Uma outra forma de extração dos componentes principais de discriminação também foi proposta em [94]. Nesta abordagem (vide a Figura A.4), a extração dos componentes difere no fato de que a camada de projeção nos PCD possui função de ativação linear, e a saída desta camada alimenta um discriminador não linear, que também é treinado a cada extração. Adicionalmente, a cada extração, remove-se do conjunto de dados originais (\mathbf{X}) a informação projetada nas direções dos componentes já extraídos (\mathbf{W}) fazendo-se

$$\mathbf{X}' = \mathbf{W}^T \mathbf{W} \mathbf{X} \quad (\text{A.5})$$

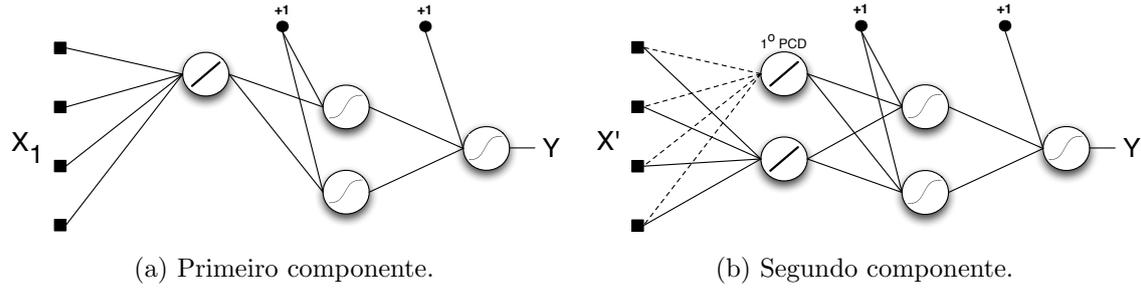


Figura A.4: Esquema de extração dos componentes principais ortogonais de discriminação.

com isso, garante-se que os componentes extraídos serão ortogonais entre si. Um problema com esta técnica é que o resultado obtido pode ser dependente do número de neurônios na segunda camada escondida, de tal forma que pode se fazer necessário vários testes, com diferentes topologias, para se determinar o melhor número de neurônios nesta camada.

A.3 Análise de Componentes Independentes

A análise de componentes independentes (ICA) [87] é uma técnica de processamento de sinal multidimensional que busca por uma transformação linear dos dados de tal forma que sua estrutura essencial fique mais acessível. Na ICA, as variáveis, após esta transformação, tornam-se estatisticamente independentes.

No modelo padrão de ICA, os vetores de sinais observados $\mathbf{x} = [x_1, x_2, \dots, x_N]^T$ são considerados como gerados a partir da combinação linear das fontes independentes $\mathbf{s} = [s_1, s_2, \dots, s_N]^T$

$$x_i = \sum_{j=1}^N a_{ij} s_j \rightarrow \mathbf{x} = \mathbf{A} \mathbf{s} \quad (\text{A.6})$$

onde $i = 1, \dots, N$ e \mathbf{A} é a matriz de mistura das fontes independentes. O modelo de ICA tem sido amplamente utilizado em uma variedade de tarefas de processamento de sinais [95, 96].

O propósito da ICA é estimar as fontes independentes \mathbf{s} e a matriz de mistura \mathbf{A} usando apenas os dados observados \mathbf{x} . Isto pode ser obtido através do modelo

inverso

$$\hat{\mathbf{s}} = \mathbf{W}\mathbf{x} \quad (\text{A.7})$$

onde os coeficientes da matriz estimada \mathbf{W} são obtidos considerando-se que os componentes de $\hat{\mathbf{s}}$ são estatisticamente independentes (ou pelo menos o mais independente possível).

Existem, porém, algumas indeterminações no modelo de ICA. A ordem de extração dos componentes independentes não é garantida, e os componentes extraídos podem diferir dos componentes originais por um fator multiplicativo (positivo ou negativo). Por sorte, estas limitações são insignificantes em boa parte das aplicações.

O modelo padrão de ICA assume um sistema de misturas onde o número de fontes independentes é igual ao número de sensores (observadores). Em problemas práticos, esta suposição nem sempre é verdadeira. Quando o número de fontes é maior do que o número de sensores, a recuperação das fontes é aproximada através de métodos específicos para estes casos [97, 98]. Para casos onde o número de fontes (K) é menor do que o número de sensores (N), pode-se empregar alguma técnica de compactação de sinais, tal como PCA. Como uma alternativa voltada para utilização de ICA em problemas de classificação de sinais, compactação via PCD também pode ser utilizada [99].

A minimização da dependência estatística é o âmago de qualquer algoritmo de extração de componentes independentes, uma vez que esta minimização leva à estimação da matriz de mistura (e, conseqüentemente, aos componentes independentes).

A.3.1 Independência Estatística

Considerando dois vetores independentes \mathbf{v}_1 e \mathbf{v}_2 , eles serão estatisticamente independentes se, e somente se

$$p_{\mathbf{v}_1, \mathbf{v}_2}(\mathbf{v}_1, \mathbf{v}_2) = p_{\mathbf{v}_1}(\mathbf{v}_1)p_{\mathbf{v}_2}(\mathbf{v}_2) \quad (\text{A.8})$$

onde $p_{\mathbf{v}_1}(\mathbf{v}_1)$, $p_{\mathbf{v}_2}(\mathbf{v}_2)$ são, respectivamente, as funções densidade de probabilidade (fdp) de \mathbf{v}_1 and \mathbf{v}_2 e $p_{\mathbf{v}_1, \mathbf{v}_2}(\mathbf{v}_1, \mathbf{v}_2)$ é a fdp conjunta [100]. Em aplicações típicas de

ICA, tem-se, normalmente, muito pouco conhecimento sobre a fonte dos sinais, e, conseqüentemente, a estimação da fdp dos mesmos é uma tarefa complicada. Desta forma, medidas alternativas de independência são comumente empregadas durante a busca pelos componentes independentes [87, 101].

Descorrelação Não-Linear

Duas variáveis aleatórias (u_1 and u_2) de média zero são consideradas linearmente decorrelacionadas se a correlação cruzada $R_{u_1u_2}$ das mesmas é zero (utiliza-se $E\{\cdot\}$ para representar o operador de média)

$$R_{u_1u_2} = E\{u_1u_2\} \quad (\text{A.9})$$

Variáveis independentes são decorrelacionadas, embora o contrário nem sempre seja verdadeiro. A correlação linear é verificada analisando-se os momentos de primeira e segunda ordem do processo (média e variância), enquanto que a independência precisa, também, de cumulantes de ordem superior (requerendo, direta ou indiretamente, o cálculo dos mesmos).

Considerando $g(u_1)$ e $f(u_2)$ funções integráveis de u_1 and u_2 , respectivamente, pode ser provado que, se a equação A.10 é válida para quaisquer funções $g(\cdot)$ e $f(\cdot)$, então u_1 e u_2 são independentes.

$$E\{g(u_1)f(u_2)\} = E\{g(u_1)\}E\{f(u_2)\} \quad (\text{A.10})$$

Ao escolher-se $g(\cdot)$ and $f(\cdot)$ como funções não lineares, a estatística de ordem superior do problema pode ser (indiretamente) acessada. A medida de independência estatística fornecida pela equação A.10 é frequentemente chamada de *decorrelação não linear* entre u_1 and u_2 [102].

Uma limitação prática ocorre quando tenta-se aplicar esta medida em um algoritmo de ICA, uma vez que não é possível verificar todas as funções integráveis $g(\cdot)$ e $f(\cdot)$. Entretanto, estimativas dos componentes independentes são frequentemente obtidas enquanto for garantida a decorrelação não linear para um conjunto finito de funções não lineares [102].

Estatística de Ordem Superior

Outro princípio que pode ser adotado para estimar a dependência entre variáveis aleatórias advém do teorema do limite central [103]. Este teorema diz que a distribuição obtida pela soma de duas variáveis aleatórias resultará em uma distribuição mais próxima de uma gaussiana do que as distribuições originais. Uma vez que os sinais observados (\mathbf{x}) são considerados uma combinação linear entre fontes independentes (\mathbf{s}), as distribuições dos sinais observados serão mais próximas de uma gaussiana do que a distribuição das fontes independentes. Desta forma, os componentes independentes podem ser obtidos através da maximização da não gaussianidade [87].

Sabe-se que, para variáveis aleatórias gaussianas, os cumulantes de ordem mais alta que a segunda são todos nulos. Consequentemente, medidas de não-gaussianidade (e, conseqüentemente, independência) podem ser obtidas utilizando-se cumulantes de ordem superior, tais como a *kurtosis* (κ_4), que, para uma variável aleatória u de média zero, é definida por [87]

$$\kappa_4 = E\{u^4\} - 3[E\{u^2\}]^2 \quad (\text{A.11})$$

Medidas de Independência por Teoria da Informação

Medidas alternativas da independência estatística podem ser obtidas pela teoria da informação [104]. Um conceito básico definido por esta teoria é a *entropia diferencial* ($H(\cdot)$), que, para uma variável aleatória contínua u , com densidade $p_u(\cdot)$, é definida como [105]

$$H(u) = - \int_{-\infty}^{+\infty} p_u(\xi) \log p_u(\xi) d\xi \quad (\text{A.12})$$

Um importante resultado da entropia diferencial é que uma variável gaussiana possuirá sempre a maior entropia diferencial entre todas as variáveis aleatórias de mesma média e variância [106]. Desta forma, a entropia diferencial pode ser empregada como uma medida de não-gaussianidade.

A Negentropia $J(u)$ de uma variável aleatória u é definida por

$$J(u) = H(u_{gauss}) - H(u) \quad (\text{A.13})$$

onde u_{gauss} é uma variável aleatória gaussiana com mesma média e variância que u . A vantagem de se usar a negentropia, no lugar da entropia, é que a primeira é sempre não-negativa e igual a zero quando u for gaussiana. Um problema, entretanto, com o cálculo da entropia diferencial (e conseqüentemente da negentropia) é a estimação da fdp. Para evitar este problema, aproximações baseadas em cumulantes de ordem superior ou funções não-polinomiais são frequentemente adotadas [107].

A informação mútua $I(u_1, u_2, \dots, u_m)$ entre m variáveis aleatórias u_1, u_2, \dots, u_m é obtida por [79]

$$I(u_1, u_2, \dots, u_m) = \sum_{i=1}^m H(u_i) - H(\mathbf{v}) \quad (\text{A.14})$$

É sabido que a entropia para um vetor aleatório $\mathbf{v} = [u_1, u_2, \dots, u_m]$ é sempre menor que a soma de $H(u_i)$, a não ser que as variáveis de \mathbf{v} sejam independentes. Conseqüentemente, a minimização da informação mútua também pode conduzir à independência [87].

A.3.2 Algoritmos de Extração de Componentes Independentes

Atualmente, existe um grande número de algoritmos eficientes para a extração de componentes independentes. Estes algoritmos, de maneira geral, utilizam as medidas de independência apresentadas na Seção A.3.1. Entre eles, o *Joint Approximate Diagonalization of Eigenmatrices* (JADE) [108] e o *FastICA* [109] são os mais populares, e serão apresentados a seguir.

FastICA

Considerando as medidas de independência propostas na Seção A.3.1, a primeira escolha para um algoritmo de otimização utilizando as figuras de mérito apresentadas seria baseado no vetor gradiente. Estes algoritmos são simples de implementar e apresentam baixo requisito computacional. Entretanto, uma limitação para estes

algoritmos é a baixa taxa de convergência, e o fato de uma má escolha da taxa de aprendizado pode comprometer a convergência do treinamento [110].

O algoritmo de ponto fixo FastICA foi primeiramente proposto em [109], e formulado através de iterações newtonianas. Entre as vantagens desta abordagem, pode-se mencionar as taxas de convergência mais rápidas e confiáveis, além da simplicidade computacional [109, 110].

O algoritmo FastICA, para sinais previamente branqueados, é o seguinte:

1. Branqueie o sinal de entrada \mathbf{x} para obter \mathbf{z} ;
2. Escolha um vetor \mathbf{w} iniciado aleatoriamente, com norma unitária;
3. Faça $\mathbf{w}^+ = E\{\mathbf{z}g(\mathbf{w}^T\mathbf{z})\} - E\{g'(\mathbf{w}^T\mathbf{z})\}\mathbf{w}$;
4. Faça $\mathbf{w} = \frac{\mathbf{w}^+}{\|\mathbf{w}^+\|}$
5. Se não convergiu, volte ao passo 3;

onde $g'(\cdot)$ no passo 2 é a derivada de $g(\cdot)$. Tipicamente, as seguintes não linearidades $g(\cdot)$ (e suas respectivas derivadas $g'(\cdot)$) são utilizadas [109]:

$$g_1(u) = \frac{1}{a_1} \log(\cosh(a_1 u)) \rightarrow g'_1(u) = \tanh(a_1 u) \quad (\text{A.15})$$

$$g_2(u) = -\frac{1}{a_2} e^{-\frac{a_2 u^2}{2}} \rightarrow g'_2(u) = u e^{-\frac{a_2 u^2}{2}} \quad (\text{A.16})$$

$$g_3(u) = \frac{1}{4} u^4 \rightarrow g'_3(u) = u^3 \quad (\text{A.17})$$

onde $1 < a_1 < 2$ e $a_2 \approx 1$. Aplicações práticas [109] mostram que g_1 é uma boa função para aplicações gerais. g_2 é indicada quando os componentes independentes são muito supergaussianos, e g_3 só deve ser empregada para estimar fontes subgaussianas, onde também não existam *outliers*.

De forma a estimar múltiplos componentes independentes, algoritmos baseados na ortogonalização por deflação, tais como o método de Gram-Schmidt [87] podem ser adotados. Entretanto, técnicas baseadas no FastICA para a extração simultânea dos componentes independentes também foram desenvolvidas [87, 109, 110].

Joint Approximate Diagonalization of Eigenmatrices

No algoritmo JADE, estatísticas de segunda e quarta ordem são empregadas para a estimação dos componentes independentes através de uma aproximação por tensores. O cumulante de segunda ordem (matriz de covariância) é utilizado para assegurar que as variáveis estão branqueadas. A informação de quarta ordem (obtida pela matriz de tensores de cumulantes de quarta ordem) provê o critério de independência.

Tensores são considerados como uma generalização de alta-dimensão de matrizes e operadores lineares [111]. Tensores de cumulantes são matrizes contendo cumulantes-cruzados¹. Considerando este fato, o tensor de cumulantes de segunda ordem é a matriz de covariância, e o tensor de quarta ordem (\mathbf{T}_4) é formado pelos cumulantes cruzados de quarta ordem ($cum(u_i, u_j, u_k, u_l)$), que, para variáveis aleatórias de média nula, são definidos por

$$cum(u_i, u_j, u_k, u_l) = E\{u_i, u_j, u_k, u_l\} - E\{u_i, u_j\}E\{u_k, u_l\} - E\{u_i, u_k\}E\{u_j, u_l\} - E\{u_k, u_j\}E\{u_i, u_l\} \quad (\text{A.18})$$

O tensor de cumulantes de quarta ordem \mathbf{T}_4 é uma estrutura com 4 dimensões, onde, para cada elemento $q_{ijkl} = cum(u_i, u_j, u_k, u_l)$, os índices i, j, k, l variam de 1 à N (onde N é o número de variáveis aleatórias). O tensor de cumulantes de quarta ordem contém toda a informação de quarta ordem dos sinais envolvidos.

O critério de estimação JADE é obtido através de um procedimento análogo à diagonalização da matriz de covariância, que provê a decorrelação de sinais. Como \mathbf{T}_4 é a contrapartida de quarta ordem da matriz de covariância, a independência pode ser obtida através da diagonalização de \mathbf{T}_4 , uma vez que, para sinais independentes, cumulantes-cruzados de quarta ordem serão diferentes de zero somente quando $i = j = k = l$. De maneira análoga ao caso de segunda ordem, a diagonalização dos tensores de quarta ordem pode ser obtida através de decomposição singular [87].

A utilização de métodos tensoriais para a extração de componentes independentes é, em teoria, simples. Entretanto, computar a EVD de matrizes com quatro dimensões através de algoritmos ordinários requer uma grande quantidade de memória, podendo ser, em alguns casos, computacionalmente proibitiva. Para evitar tais li-

¹De maneira análoga ao existente em matrizes de correlação cruzada de variáveis aleatórias.

mitações, métodos como o JADE foram propostos na literatura. O algoritmo JADE busca pela matriz \mathbf{W} que minimiza a soma dos quadrados dos elementos não pertencentes à diagonal principal de $\mathbf{T}_4^{(\hat{\mathbf{s}})}$ (onde $\mathbf{T}_4^{(\hat{\mathbf{s}})}$ é o tensor de cumulantes de quarta ordem da matriz de estimação das fontes independentes $\hat{\mathbf{s}}$). Maiores detalhes sobre este algoritmo podem ser vistos em [112].

Apêndice B

Sistema de Coordenadas do ATLAS

O sistema de coordenada do ATLAS é um sistema cartesiano que segue a regra da mão direita. Neste sistema, apresentado na Figura B.1, o eixo x tem seu lado positivo apontando para o centro do anel do LHC, z segue a direção do feixe de partículas, com seu lado positivo apontando para o ponto 8 na Figura B.1 e o eixo y aponta para cima, com seu lado positivo apontando para a superfície.

Para análise de colisões, entretanto, o sistema cartesiano nem sempre é o mais utilizado. Nestes casos, normalmente se utiliza um sistema que acompanha a direção das partículas provenientes do ponto de colisão. Consequentemente, as coordenadas empregadas são η , ϕ e z em contraposição às coordenadas cartesianas x , y e z . As coordenadas η , ϕ e θ seguem uma transformação não linear de x , y e z :

$$\phi = \arctan\left(\frac{x}{y}\right) \quad (\text{B.1})$$

$$\theta = \arctan\left(\frac{x}{z}\right) \quad (\text{B.2})$$

$$\eta = -\log\left(\tan\left(\frac{\theta}{2}\right)\right) \quad (\text{B.3})$$

A Figura B.2 explica o sistema. Em sua parte superior, é possível ver o diagrama esquemático do ATLAS, mostrando como se comportam as coordenadas, tomando por referência as coordenadas cartesianas x , y e z . Nota-se que a variável ϕ representa a rotação e a variável η (chamada de pseudorapidez) representa a direção de projeção das partículas, após a colisão [44].

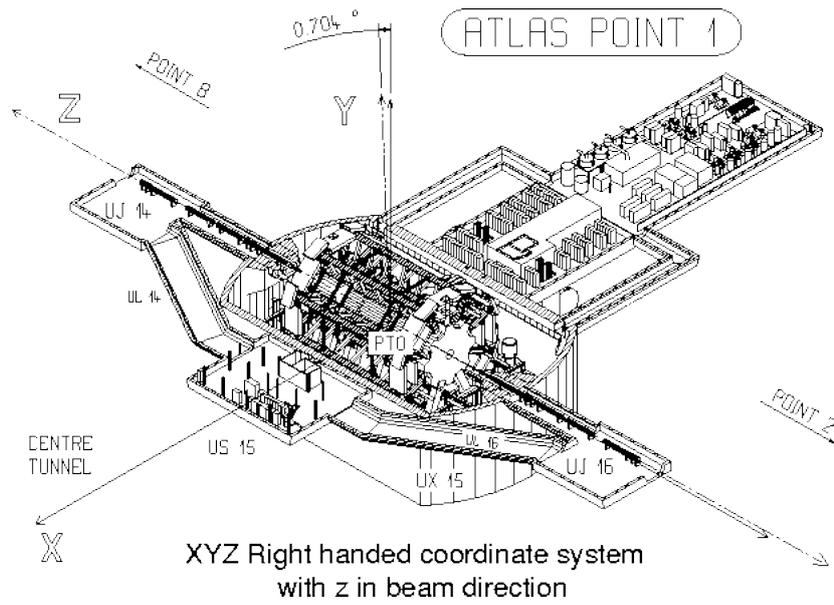


Figura B.1: Sistema cartesiano de coordenadas do ATLAS (extraído de [12]).

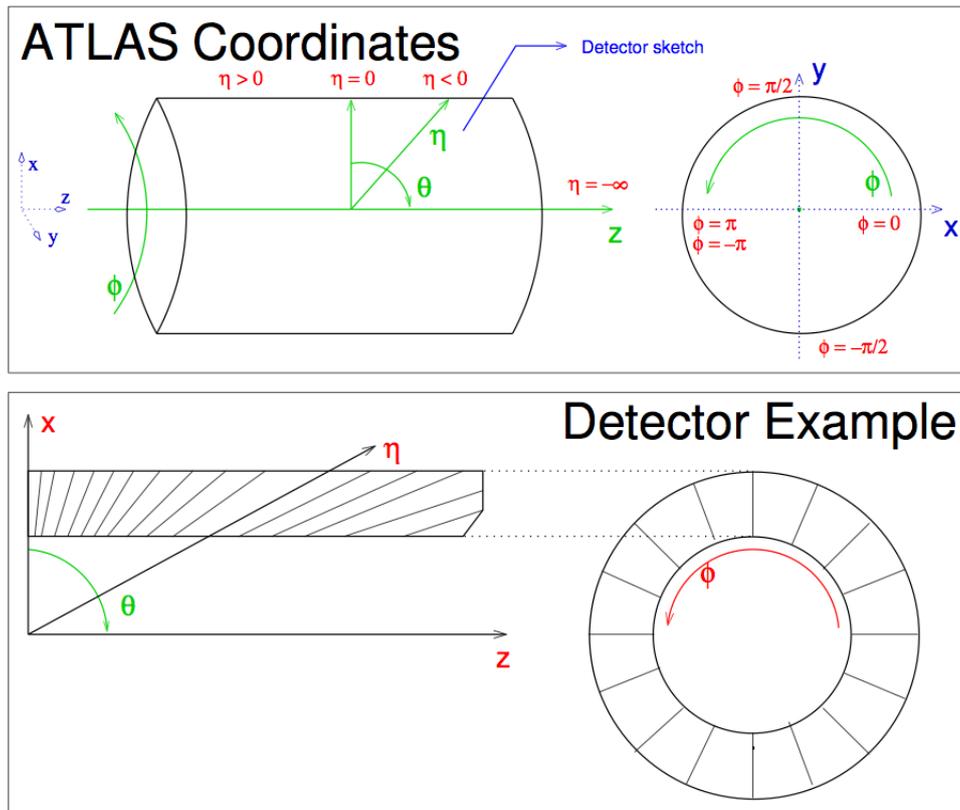


Figura B.2: O sistema de coordenadas do ATLAS.

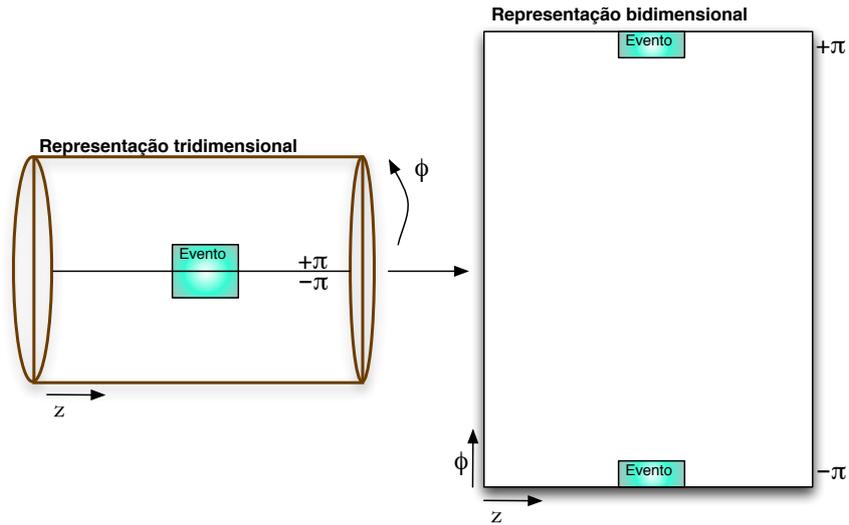


Figura B.3: Visualização do problema de extrapolação da coordenada ϕ (*wrap-around*).

Um problema comum em análises topológicas em geometrias cilíndricas ocorre quando um evento detectado fica, em ϕ , muito próximo de $\pm\pi$, pois, caso o centro esteja próximo de $-\pi$, por exemplo, possivelmente haverá canais de leitura com coordenadas próximas de $+\pi$, gerando uma descontinuidade na leitura do evento, visto que muitas ferramentas de análise interpretam o detetor como um gráfico bidimensional, com limites para ϕ em $(-\pi, +\pi]$ (veja a Figura B.3). Desta forma, cálculos utilizando esta variável devem atentar para este fato e aplicar correções, se necessário.

Nota-se que, quando se alcança o eixo z , tem-se $\eta = \infty$. Isto significa que objetos com valores grandes em η representam colisões onde as partículas do feixe apenas se desviaram, dificilmente produzindo eventos relevantes. Desta forma, é comum utilizarem-se detetores com baixa resolução quando $\eta > 3$. Na parte inferior da Figura B.2, é possível ver um exemplo de como um detetor genérico é segmentado, acompanhando as coordenadas η e ϕ .

Apêndice C

Lista de Publicações

Nesta seção, apresentamos os artigos relacionados ao desenvolvimento desta tese, publicados em congressos e revistas nacionais e internacionais. Os artigos estão organizados em ordem cronológica, e acompanham breve descrição.

C.1 Capítulos de Livros

1. TORRES, R. C., SIMAS FILHO, E., DE LIMA, D. E. F., SEIXAS, J. M., *Segmented Online Neural Filtering System Based on Independent Components of Pre-processed Information*. Intech, 2009. (Aguardando Publicação)

Neste trabalho, o sistema de discriminação elétron / jato desenvolvido nesta tese é apresentado. A capítulo aborda a combinação entre o conhecimento especialista do problema e a utilização de técnicas de pré-processamento baseadas na estatística do processo para melhor evidenciar a informação relevante para a discriminação. Técnicas lineares e não lineares de decorrelação são empregadas e o resultado destas possibilitou observar que o pré-processamento eficiente da informação, antes do teste de hipóteses permite simplificar a topologia do classificador neural empregado, sem impactos na eficiência de classificação.

2. SEIXAS, J. M., E SOUZA FILHO, J. B. DE O., TORRES, R. C., TCHEOU, M. P., *Digital Signal Processing*. Livraria da Física/IF/UFRJ, 2006.

Neste trabalho, desenvolvido para um curso na área de física experimental, é

apresentado uma introdução à técnicas de processamento de sinais, com ênfase em processamento digital de sinais. Como caso de uso, um sistema de detecção de múons foi desenvolvido utilizando filtragem casada. Para validar a viabilidade de operação *online* do detetor desenvolvido, o mesmo foi implementado na tecnologia de processadores digitais de sinais (DSP), onde comprova-se a eficácia desta arquitetura, em aplicações de processamento de sinais.

C.2 Artigos Publicados em Revista

1. RIU, I., TORRES, R. C., SEIXAS, J. M., et al., “Integration of the Trigger and Data Acquisition Systems in ATLAS”, *IEEE Transactions on Nuclear Science*, v. 55, n. 1, pp. 106–112, fevereiro 2008.

Durante o ano de 2006 e 2007 foram obtidos diversos progressos no que tange a integração do TDAQ com os detetores do ATLAS. Foi desenvolvida uma configuração para o TDAQ, já contendo aproximadamente 80 processadores alocados para o modelo final. Vários ensaios técnicos foram elaborados envolvendo toda a cadeia de filtragem do TDAQ, e aspectos críticos para o sistema final, como tempos de processamento, foram estudados usando diferentes algoritmos de filtragem, bem como diferentes módulos do sistema de fluxo de dados.

2. SIMÕES, J. A., DOBSON, M., TORRES, R. C., et al., “The ATLAS DAQ System Online Configurations Database Service Challenge”, *Journal of Physics: Conference Series*, v. 119, n. 022004, pp. 1–11, 2008.

Apresenta os requisitos necessários para os serviços de configuração do sistema de filtragem do ATLAS. A proposta desenvolvida para este serviço é discutida e comparada com métodos baseados em base de dados relacionais. Os resultados apresentados justificam a escolha da metodologia proposta para prover o serviço de configuração do TDAQ.

3. ABOLINS, M., ADRAGNA, P., ALEKSANDROV, E., TORRES, R. C., et al., “Integration of the Trigger and Data Acquisition Systems in ATLAS”, *Journal of Physics: Conference Series*, v. 119, n. 2, pp. 1–10, 2008.

Apresenta os progressos obtidos durante os testes integrados realizados entre 2006 e 2007 com o sistema de filtragem do ATLAS. Estes testes foram realizados com os equipamentos já instalados junto ao detetor. Testes utilizando colisões próton-próton simuladas foram realizados utilizando toda a cadeia de processamento do sistema de filtragem. Por fim, a escalabilidade do sistema foi testada, e parâmetros críticos para o experimento, tais como tempos de latência e taxas de aceitação foram calculados.

4. TORRES, R. C., SEIXAS, J. M., DOS ANJOS, A., et al., “Online Electron/Jet Neural High-level Trigger Over Independent Calorimetry Information”, *Proceedings of Science*, , n. PoS(ACAT)039, pp. 1–15, 2008.

O processo de discriminação elétron / jato no segundo nível de filtragem do TDAQ é abordado. Neste trabalho, cada evento de calorimetria é pré-processado topologicamente usando soma em anéis, e, em seguida, as componentes independentes dos mesmos são extraídas e utilizadas para treinar uma rede neural artificial. Os resultados obtidos mostram que o modelo proposto atinge níveis de eficiência superiores ao modelo atualmente em uso no segundo nível de filtragem do TDAQ.

5. KORDAS, K., ABOLINS, M., ALEXANDROV, I., TORRES, R. C., et al., “The ATLAS Data Acquisition and Trigger: concept, design and status”, *Nuclear Physics B - Proceedings Supplements*, v. 172, pp. 178–182, outubro 2007.

Este artigo apresenta o desenho básico e a implementação do sistema de filtragem do ATLAS. Estudos mais específicos para os módulos de fluxo de dados e filtragem *online* são realizados. Adicionalmente, o estado atual da instalação e testes de validação dos componentes destes sistemas é apresentado e discutido.

6. DOS ANJOS, A., TORRES, R. C., SEIXAS, J. M., et al., “Neural Triggering System Operating on High Resolution Calorimetry Information”, *Nuclear Instruments and Methods in Physics Research*, v. 559, pp. 134–138, maio 2006.

Apresenta o sistema de discriminação neural para operação no segundo nível de filtragem do TDAQ usando informações de calorimetria. Para a redução da

dimensão dos eventos, o método topológico de soma em anéis é adotado. Os anéis gerados alimentam uma rede neural artificial, encarregada do processo de decisão final. O modelo proposto atingiu 97% de eficiência de detecção de elétrons para um falso alarme de apenas 3%. O processo total de decisão gasta apenas 500 μ s, tornando-o adequado para operação *online*.

C.3 Artigos Publicados em Anais de Congressos

1. TORRES, R. C., DE LIMA, D. E. F., SIMAS FILHO, E., et al., “Neural Online Filtering Based on Preprocessed Calorimeter Data”, *IEEE Nuclear Science Symposium Conference Record*, v. 1, n. N13-90, pp. 530–536, outubro 2009.

Neste trabalho, é apresentado o sistema neural de discriminação elétron / jato baseado em anéis topológicos. Para melhorar a compactação e a decorrelação entre os anéis, um pré-processamento segmentado é apresentado. A informação segmentada é projetada nas componentes principais (PCA) e nas componentes principais de discriminação (PCD) e o resultado é comparado em termos de taxas de compactação e eficiência de classificação. Adicionalmente, o impacto da decorrelação da informação de entrada na complexidade da rede neural é estudado.

2. SIMAS FILHO, E. F., TORRES, R. C., SEIXAS, J. M., et al., “Combinação de Classificadores Neurais Segmentados Com Pré-Processamento por Análise de Componentes Independentes para um Sistema Online de Filtragem”, *Anais do IX Congresso Brasileiro de Redes Neurais / Inteligência Computacional*, pp. 1–7, 2009, Ouro Preto, Minas Gerais.

Neste trabalho é proposto o uso de classificadores neurais especialistas em cada camada dos calorímetros do ATLAS. A análise de componentes independentes é aplicada de modo segmentado (por camada) aos sinais dos calorímetros como pré-processamento. Alguns métodos de combinação de classificadores foram utilizados para produzir a decisão global a partir das saídas dos diversos classificadores.

3. TORRES, R. C., SEIXAS, J. M., “Configuração Automática para um Sistema de Filtragem Online de Alta Complexidade”, *Congresso Brasileiro de Automática (CBA)*, pp. 1–6, 2008, Juiz de Fora, Minas Gerais.

Neste artigo, o mecanismo automatizado para a geração de base de dados de configuração da infraestrutura do TDAQ é apresentado. Um modelo provendo a automatização da configuração de toda a cadeia de filtragem é apresentado, e os resultados mostram que a proposta encontra-se amplamente difundida na comunidade do TDAQ, sendo amplamente usada em testes de larga escala.

4. BURCKHART-CHROMEK, D., TORRES, R. C., DOS ANJOS, A., et al., “Testing on a Large Scale: Running the ATLAS Data Acquisition and High Level Trigger Software on 700 PC Nodes”. In: *Proceedings of the Computing in High Energy and Nuclear Physics (CHEP)*, pp. 1–6, 2006, Mumbai, Índia.

Este artigo apresenta os resultados obtidos com os testes em larga escala do sistema de filtragem do ATLAS, com um máximo de 700 nós de processamento. Os resultados dos testes permitiram que inúmeras melhorias do TDAQ pudessem ser implementadas, além da identificação de áreas críticas, cuja visualização só é possível com a utilização de um grande número de nós de processamento.

5. UNEL, G., ABOLINS, M., ADRAGNA, P., TORRES, R. C., et al., “Studies with the ATLAS Trigger and Data Acquisition Pre-Series Setup”, *Computing in High Energy Physics (CHEP)*, , n. ATL-DAQ-CONF-2006-019. ATL-COM-DAQ-2006-010, pp. 922–926, 2006, Mumbai, Índia..

Estudos de performance do sistema de filtragem do ATLAS são conduzidos em um *cluster* de máquinas com características similares daquelas a serem empregadas no sistema final. Os estudos permitiram validar a escolha de tecnologias feita para o sistema de filtragem. Por fim, testes foram realizados sem a utilização de algoritmos de seleção de eventos. Para estes testes, foi comprovado que os componentes adquiridos atendem às especificações do ATLAS.

6. DOS ANJOS, A., TORRES, R. C., FERREIRA, B. C., XAVIER, T. C., SEIXAS, J. M., “Discriminação Neural de Elétrons no Segundo Nível do Trigger

do ATLAS”, *Encontro Nacional de Física de Partículas e Campos*, pp. 1–5, 2005, São Lourenço, Minas Gerais.

Este trabalho apresenta um discriminador neural para o segundo nível de filtragem do ATLAS, atuando no problema de separação elétron/jato baseado em informações de calorimetria. Para reduzir a alta dimensionalidade dos dados de entrada, as regiões de interesse (RoI) identificadas no primeiro nível são organizadas em anéis concêntricos de deposição energética. Em caráter comparativo, o sistema proposto foi também implementado usando a tecnologia DSP.

7. DOS ANJOS, A., TORRES, R. C., FERREIRA, B. C., XAVIER, T. C., SEIXAS, J. M., “Otimização do Sistema de Trigger do Segundo Nível do ATLAS Baseado em Calorimetria”, *Encontro Nacional de Física de Partículas e Campos*, pp. 1–8, 2005, São Lourenço, Minas Gerais.

Este trabalho apresenta um discriminador neural que opera sobre as quantidades calculadas pelo algoritmo T2Calo, responsável pela detecção elétron/jato no Segundo Nível de Filtragem do experimento ATLAS. Este sistema de detecção melhora a eficiência de detecção em quase 10 pontos percentuais, mantendo um nível de desempenho compatível com as restrições operacionais do sistema de filtragem.

C.4 Resumos Publicados em Anais de Congressos

1. TORRES, R. C., SEIXAS, J. M., “Ferramenta de Configuração para o Sistema de Filtragem do ATLAS”, *Encontro Nacional de Física de Partículas e Campos*, 2007, Águas de Lindóia, São Paulo.

É apresentado o estado atual da o mecanismo de configuração automática da infraestrutura do sistema de filtragem de alto nível do ATLAS. Novas possibilidades de operação foram introduzidas, como o suporte a múltiplos servidores RDB e IS.

2. TORRES, R. C., SEIXAS, J. M., “Ferramenta de Configuração para o Sistema de Filtragem do ATLAS”, *Encontro Nacional de Física de Partículas e*

Campos, 2006, Águas de Lindóia, São Paulo.

É apresentada a primeira abordagem para a automatização da configuração da infraestrutura do TDAQ. Nesta abordagem, já é possível configurar toda a cadeia de filtragem em alto nível, gerando grande facilidade de operação do sistema de filtragem.