

Universidade do Estado do Rio de Janeiro Centro de Tecnologia e Ciências Instituto de Física Armando Dias Tavares

Victor Almeida de Assis

Fusão de informação com o NeuralRinger do Trigger do ATLAS para classificação de elétrons Boosted

Rio de Janeiro 2024 Victor Almeida de Assis

# Fusão de informação com o NeuralRinger do Trigger do ATLAS para classificação de elétrons Boosted



Orientadora: Profa. Dra. Marcia Begalli Coorientador: Prof. Dr. José Manoel de Seixas

> Rio de Janeiro 2024

#### CATALOGAÇÃO NA FONTE UERJ/ REDE SIRIUS / BIBLIOTECA CTC/D

A848f	Assis, Victor Almeida de. Fusão de informação com o NeuralRinger do Trigger do ATLAS para classificação de elétrons boosted / Victor Almeida de Assis. – 2024. 147 f. : il.
	Orientadora: Marcia Begalli. Coorientador: José Manoel de Seixas. Dissertação (mestrado) - Universidade do Estado do Rio de Janeiro, Instituto de Física Armando Dias Tavares.
	<ol> <li>Elétrons – Classificação - Teses. 2. Partículas (Física nuclear) – Teses.</li> <li>Experimento ATLAS – Teses. 4. Redes neurais (Computação) – Teses.</li> <li>Calorimetria – Teses. 6. Modelo padrão – (Física nuclear) – Teses. 7. Grande colisor de hádrons (França e Suíça) – Teses. I. Begalli, Marcia (Orient.). II. Seixas, José Manoel de (Coorient.). III. Universidade do Estado do Rio de Janeiro. Instituto de Física Armando Dias Tavares. IV. Título.</li> </ol>
	CDU 539.124:001.82

Bibliotecária: Teresa da Silva CRB7/5209

Autorizo, apenas para fins acadêmicos e científicos, a reprodução total ou parcial desta dissertação, desde que citada a fonte.

Assinatura

Data

#### Victor Almeida de Assis

# Fusão de informação com o NeuralRinger do Trigger do ATLAS para classificação de elétrons Boosted

Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós Graduação em Física, da Universidade do Estado do Rio de Janeiro.

Aprovada em 29 de fevereiro de 2024.

Banca Examinadora:

arcia Dural.

Profa. Dra. Marcia Begalli (Orientadora)

Instituto de Física Armando Dias Tavares - UERJ

Prof. Dr. José Manoel de Seixas (Coorientador)

Universidade Federal do Rio de Janeiro

Profa. Dral Yara do Amaral Coutinho Universidade Federal do Rio de Janeiro

Prof. Dr. Natanael Nunes de Moura Junior

Universidade Federal do Rio de Janeiro

de ter

Prof. Dr. Dilson)de Jesus Damião

Instituto de Física Armando Dias Tavares - UERJ

Wayner le Parl Canoch

Prof. Dr. Wagner de Paula Carvalho Instituto de Física Armando Dias Tavares - UERJ

> Rio de Janeiro 2024

# DEDICATÓRIA

A minha primeira professora de Física que dava aulas antes mesmo de eu ir à escola, minha mãe, Sandra Helena.

#### AGRADECIMENTOS

Agradeço aos meus pais, Sandra Helena e Francisco Sebastião, por me proporcionar um ambiente favorável para que eu possa estudar e por todo apoio nas minhas decisões e pelos conselhos.

Agradeço aos meus orientadores, Marcia Begalli e José Manoel de Seixas, por todo apoio e conselhos para a realização deste trabalho. Agradeço em especial à Marcia Begalli que me acompanha desde que entrei na UERJ no Masterclass até hoje.

Agradeço à toda a equipe do Laboratório de Processamento de Sinais (LPS) por todo suporte e sugestões durante nossas reuniões semanais e fora delas. Em especial, agradeço ao Natanael Nunes de Moura Junior por liderar a equipe e pelos conselhos, ao Pedro Lima e Lucas Nunes que me auxiliaram me integrando ao sistema do LPS independente do dia e horário.

Agradeço à Secretaria do PPGF, Ranna e Samir, por todo auxilio rápido no fornecimento de informações e documentações sobre o curso. Agradeço à meus professores, Nilson, Guimarães, Luís Fernando e Mahon por toda a paciência em minhas dúvidas e pelas ótimas aulas.

Agradeço aos meus colegas do PPGF pela companhia e conversas, em especial ao Gabriel e ao grupo da copa com o nosso café pontual, Hellen, João Paulo, Higor, Fillipe, Felipe e Karol.

Agradeço ao grupo do Projeto de extensão Pi-EF por me ajudar a conciliar meu mestrado com a divulgação científica, em especial, ao nosso coordenador, Andreson LCR que sempre procurou o melhor para todos do grupo.

Agradeço a CAPES, CNPq e FAPERJ por todo apoio ao projeto e em especial, a CAPES pelo apoio financeiro direto.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Não poderia deixar de agradecer aos profissionais, funcionários e colegas da minha outra "academia", a academia Evidence, que contribuíram para o meu bem-estar físico e mental durante toda essa trajetória. Em especial aos professores que auxiliaram diretamente no meu desenvolvimento e recuperação, Daniel, Esteves, Isabel e João Paulo.

O que observamos não é a própria natureza, mas a natureza exposta a nosso método de questionamento.  $Werner\ Heisenberg$ 

> Nós só podemos ver um pouco do futuro, mas o suficiente para perceber que há muito a fazer. Alan Turing

#### RESUMO

ASSIS, V. A. Fusão de informação com o NeuralRinger do Trigger do ATLAS para classificação de elétrons Boosted. 2024. 147 f. Dissertação (Mestrado em Física) – Instituto de Física Armando Dias Tavares, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2024.

Sistemas de filtragem *online* tipicamente têm requisitos de projeto de alta velocidade e uso limitado de memória, o que dificulta seus desenvolvimentos. Além disso, é fundamental não possuir tendências estatísticas, já que haverá o descarte irrecuperável de eventos. Nos experimentos de física de altas energias, a identificação *online* de partículas é crucial para qualquer nova descoberta ou análise de dados. Em particular, os calorímetros são essenciais para esta tarefa em diferentes experimentos, pois medem as energias das partículas incidentes e revelam a natureza destas a partir do perfil de energia que deixam no detector. Assim, no Experimento ATLAS do colisor LHC (Large Hadron Collider), o sistema de calorimetria tem papel fundamental na seleção online dos subprodutos resultantes das colisões, que ocorrem a cada 25 nanossegundos. Baseado na informação de calorimetria, um ensemble de 30 redes neurais (NeuralRinger) é atualmente utilizado para a identificação de elétrons, que são mensageiros de importantes processos físicos de interesse no LHC. Neste trabalho, avaliamos o uso da fusão de informação na detecção de elétrons que estejam próximos, combinando a informação original do NeuralRinger (anéis concêntricos de deposição de energia, construídos em torno de uma estimativa do baricentro do chuveiro de partículas produzido pela partícula incidente) com outras variáveis de calorimetria, reconhecidas pelo seu poder de discriminação de elétrons. Por fim, avaliamos a relevância destas variáveis para a construção do novo filtro online.

Palavras-chave: física experimental de altas energias; experimento ATLAS; fusão de informação aprendizado de máquina.

#### ABSTRACT

ASSIS, V. A. Data fusion for ATLAS NeuralRinger based trigger on Boosted electrons. 2024. 147 f. Dissertação (Mestrado em Física) – Instituto de Física Armando Dias Tavares, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2020.

Online filtering systems typically have high speed design requirements and limited memory use, making difficult to develop new improvements to the systems. Moreover, it is essential to have no statistical trends, as there will be the irrecoverable disposal of events. In high energy physics experiments, online particle identification is crucial for any new discovery or data analysis. In particular, the calorimeters are essential for this task in different experiments, as they measure the energies of the incident particles and also reveal their nature from the energy profile they leave in the detector. Thus, in the ATLAS experiment, at the LHC (Large Hadron Collider), the calorimetry system plays a fundamental role in online selection of by products resulting from collisions, which occur every 25 nanoseconds. Based on calorimetry information, an ensemble of 30 neural networks (NeuralRinger) is currently used for the selection of electrons, which are messengers of important Physics processes of interest in the LHC. In this work, we evaluated the use of the fusion of information in the detection of boosted electrons, combining the original information of NeuralRinger (concentric energy deposition rings, built around an estimate of baricenter from the particle shower produced by the incident particle) with other calorimetry variables, recognized for their power of electron discrimination. Finally, we evaluate the relevance of these variables for the construction of the new online filter.

Keywords: experimental high energy physics; ATLAS experiment; fusion information; machine learning.

## LISTA DE FIGURAS

Figura 1	Į .	- Modelo Padrão de Física de Partículas	19
Figura 2	2.	- Aniquilação de um elétron e de um pósitron	21
Figura 3	3.	- Ilustração de um chuveiro eletromagnético e de um hadrônico	25
Figura 4	1.	- Objeto <i>Boosted</i>	27
Figura 5	<u>5</u> .	- Decaimento da partícula X em jatos	28
Figura 6	<u>j</u> .	- Complexo de Aceleradores do CERN	30
Figura 7	7.	- Distribuição média de empilhamento < $\mu$ > em diferentes tomada de	
		dados	31
Figura 8	3.	- Experimento ATLAS	33
Figura 9	).	- Coordenadas do experimento ATLAS	33
Figura 1	10 -	- Detector interno do ATLAS	35
Figura 1	11 -	- Calorímetro eletromagnético e hadrônico do ATLAS	38
Figura 1	12 -	- Interação das partículas com todos os detectores do ATLAS $\ .\ .\ .$ .	39
Figura 1	13 -	- Barril do ECAL (acordeão)	40
Figura 1	14 .	- Detalhes de um módulo do TileCal	41
Figura 1	15 -	- Segmentação em profundidade e em $\eta$ das células do barril central e	
		barril estendido do TileCal	42
Figura 1	16 -	- Espectrômetro de múons do ATLAS	43
Figura 1	17 -	- Sistema de <i>Trigger</i> do ATLAS	44
Figura 1	18 -	- Esquemas de torres do algoritmo L1	47
Figura 1	19 -	- Trigger HLT do ATLAS para Run 2	48
Figura 2	20 -	- Torre de trigger com 10 SuperCells	53
Figura 2	21 ·	- Eficiência do <i>trigger</i> L1	54
Figura 2	22 -	- Regiões de classes divididas por um hiperplano	58
Figura 2	23 -	- Exemplo de Multi Layer Perceptron	59
Figura 2	24 -	- Método de validação cruzada múltipla <i>k-fold</i>	63
Figura 2	25 -	- Anéis do NeuralRinger	65
Figura 2	26 -	- Anéis do <i>NeuralRinger</i> por anéis em plano	66
Figura 2	27 -	- Perfil de energia dos anéis do <i>NeuralRinger</i> para elétrons	66
Figura 2	28 -	- Perfil de energia dos anéis do <i>NeuralRinger</i> para jatos	67
Figura 2	29 -	- Distribuição $E_{ratio}$	72
Figura 3	30 -	- Distribuição $R_{\eta}$	73
Figura 3	31 ·	- Distribuição $f_3$	74
Figura 3	32 -	- Distribuição $w_{\eta^2}$	74
Figura 3	33 -	- Eficiências em $p_T$ e $\Delta R$ para elétrons	76
Figura 3	34 -	- Perfil de energia dos anéis do NeuralRinger para elétrons Boosted	77

Figura 3	5 -	Perfil de energia da metade dos anéis do NeuralRinger para elétrons
		Boosted
Figura 3	6 -	· Classificação da fusão com base na entrada de dados $\dots \dots \dots$
Figura 3	7 -	· Classificação de Dasarathy
Figura 3	8 -	· Classificação de JDL $\ldots$ 82
Figura 3	9 -	Arquitetura centralizada
Figura 4	0 -	Arquitetura descentralizada
Figura 4	1 -	Arquitetura distribuída
Figura 4	2 -	Modelo de fusão de informação
Figura 4	3 -	Descrição dos modelos $\dots \dots \dots$
Figura 4	4 -	· Legenda dos modelos presentes no gráfico
Figura 4	5 -	Eficiência de identificação de elétrons (probabilidade de detecção) re-
		lativa a $E_T$ dos eventos reais (treinados)
Figura 4	6 -	Eficiência de identificação de jatos (falso alarme) como elétrons relativa
		a $E_T$
Figura 4	7 -	Eficiência de identificação de jatos (falso alarme) como elétrons relativa
		a $p_T$
Figura 4	8 -	Eficiência de identificação de elétrons (probabilidade de detecção) re-
		lativa a $E_T$ eventos simulados (elétrons <i>Boosted</i> )
Figura 4	9 -	Eficiência de identificação de elétrons (probabilidade de detecção) re-
		lativa a $p_T$ eventos simulados (elétrons <i>Boosted</i> )
Figura 5	0 -	Eficiência de identificação de elétrons (probabilidade de detecção) re-
		lativa a $\Delta R$ eventos simulados (elétrons <i>Boosted</i> )
Figura 5	1 -	Distribuição $R_{had}$
Figura 5	2 -	Quadrante dos modelos v 8 (100 anéis) contra v ssnew (6 variáveis) $\ $ . 101
Figura 5	3 -	Quadrante do modelo v 8 (100 anéis) contra os modelos de fusão $\ldots$ . 102
Figura 5	4 -	Quadrante do modelo de fusão contra os seus respectivos modelos de
		shower shape
Figura 5	5 -	Eficiência de identificação de jatos (falso alarme) como elétrons relativa
		a $E_T$ para e26 <i>lhtight</i>
Figura 5	6 -	Eficiência de identificação de jatos (falso alarme) como elétrons relativa
		a $E_T$ para e60 <i>lhmedium</i>
Figura 5	7 -	· Eficiência de identificação de jatos (falso alarme) como elétrons relativa
		a $E_T$ para e140 <i>lhloose</i>
Figura 5	8 -	· Eficiência de identificação de jatos (falso alarme) como elétrons relativa
		a $p_T$ para e26 <i>lhtight</i>
Figura 5	9 -	Eficiência de identificação de jatos (falso alarme) como elétrons relativa
		a $p_T$ para e60 <i>lhmedium</i>

Figura 60 - E	ficiência de identificação de jatos (falso alarme) como elétrons relativa	
a	$p_T$ para e140 <i>lhloose</i>	126
Figura 61 - E	ficiência de identificação de jatos (falso alarme) como elétrons relativa	
a	$\eta$ para e24 <i>lhtight</i>	127
Figura 62 - E	ficiência de identificação de jatos (falso alarme) como elétrons relativa	
a	$\eta$ para e26 lhtight	128
Figura 63 - E	ficiência de identificação de jatos (falso alarme) como elétrons relativa	
a	$\eta$ para e60 <i>lhmedium</i>	129
Figura 64 - E	ficiência de identificação de jatos (falso alarme) como elétrons relativa	
a	$\eta$ para e140 <i>lhloose</i>	130
Figura 65 - E	ficiência de identificação de jatos (falso alarme) como elétrons relativa	
a	$\mu$ para e24 <i>lhtight</i>	131
Figura 66 - E	ficiência de identificação de jatos (falso alarme) como elétrons relativa	
a	$\mu$ para e26 <i>lhtight</i>	132
Figura 67 - E	ficiência de identificação de jatos (falso alarme) como elétrons relativa	
a	$\mu$ para e60 <i>lhmedium</i>	133
Figura 68 - E	ficiência de identificação de jatos (falso alarme) como elétrons relativa	
	$\mu$ para e140 <i>lhloose</i>	134
Figura 69 - E	ficiência de identificação de elétrons (probabilidade de detecção) re-	101
l iguita do E	tiva a $E_{\pi}$ eventos simulados (elétrons <i>Boosted</i> ) para e26 <i>lhtight</i>	135
Figura 70 - E	ficiência de identificação de elétrons (probabilidade de detecção) re-	100
ligura i o Li	tiva a $E_{\pi}$ eventos simulados (elétrons <i>Boosted</i> ) para e60 <i>lhmedium</i>	
14	and a <i>L</i> <sub>T</sub> eventos sinulados (eletrons <i>Doostea</i> ) para coo <i>minicaran</i>	136
Figure 71 F	ficiência de identificação de elétrons (probabilidade de detecção) re	100
	tive a $E_{\rm c}$ eventos simulados (elétrons Reasted) para el 40 lblossa	197
Figure 79 F	feiência de identificação de elétrons <i>Doosteu</i> ) para er40 $imose$	191
	time en accentra simuladas (altrana Basatal) nom all liticit	190
	tiva a $p_T$ eventos simulados (eletrons <i>Boostea</i> ) para e20 <i>intignt</i>	138
Figura 73 - E	nciencia de identificação de eletrons (probabilidade de detecção) re-	
la	tiva a $p_T$ eventos simulados (eletrons <i>Boosted</i> ) para eou <i>lhmedium</i>	100
		139
Figura 74 - E	ficiencia de identificação de eletrons (probabilidade de detecção) re-	1 1 0
la	tiva a $p_T$ eventos simulados (elétrons <i>Boosted</i> ) para e140 <i>lhloose</i>	140
Figura 75 - E	ficiência de identificação de elétrons (probabilidade de detecção) re-	
la	tiva a $\Delta R$ eventos simulados (elétrons <i>Boosted</i> ) para e26 <i>lhtight</i>	141
Figura 76 - E	ficiência de identificação de elétrons (probabilidade de detecção) re-	
la	tiva a $\Delta R$ eventos simulados (elétrons <i>Boosted</i> ) para e60 <i>lhmedium</i>	
		142
Figura 77 - E	ficiência de identificação de elétrons (probabilidade de detecção) re-	
la	tiva a $\Delta R$ eventos simulados (elétrons <i>Boosted</i> ) para e140 <i>lhloose</i>	143

- Figura 78 Eficiência de identificação de elétrons (probabilidade de detecção) relativa a  $\eta$  eventos simulados (elétrons *Boosted*) para e24 *lhtight* . . . . 144
- Figura 79 Eficiência de identificação de elétrons (probabilidade de detecção) relativa a  $\eta$  eventos simulados (elétrons *Boosted*) para e26 *lhtight* . . . . 145
- Figura 80 Eficiência de identificação de elétrons (probabilidade de detecção) relativa a  $\eta$  eventos simulados (elétrons *Boosted*) para e60 *lhmedium* . . 146
- Figura 81 Eficiência de identificação de elétrons (probabilidade de detecção) relativa a  $\eta$  eventos simulados (elétrons *Boosted*) para el40 *lhloose* . . . 147

## LISTA DE TABELAS

Tabela 1	- Número de anéis e passo por camada do <i>NeuralRinger</i>	65
Tabela 2	- Regiões do espaço de fase do <i>NeuralRinger</i>	67
Tabela 3	- Normalização das varáveis de <i>shower shape</i>	75
Tabela 4	- Regiões do espaço de fase e a quantidade de dados de sinal e <i>background</i> .	91
Tabela 5	- Tabela de probabilidade de detecção que apresenta os valores de ${\cal P}_D$	
	(verde), $SP \in P_F(F_R)$ (falso alarme ou eficiência de background) para	
	cada região do espaço de fase com os melhores modelos selecionados	
	pelo $SP_{max}$ para o ponto de operação $tight$	92
Tabela 6	- Tabela de probabilidade de detecção que apresenta os valores de ${\cal P}_D$	
	(verde), $SP \in P_F(F_R)$ (falso alarme ou eficiência de <i>background</i> ) para	
	cada região do espaço de fase com os melhores modelos selecionados	
	pelo $SP_{max}$ para o ponto de operação <i>medium</i>	117
Tabela 7	- Tabela de probabilidade de detecção que apresenta os valores de ${\cal P}_D$	
	(verde), $SP \in P_F(F_R)$ (falso alarme ou eficiência de background) para	
	cada região do espaço de fase com os melhores modelos selecionados	
	pelo $SP_{max}$ para o ponto de operação <i>loose</i>	118
Tabela 8	- Tabela de probabilidade de detecção que apresenta os valores de ${\cal P}_D$	
	(verde), $SP \in P_F(F_R)$ (falso alarme ou eficiência de <i>background</i> ) para	
	cada região do espaço de fase com os melhores modelos selecionados	
	pelo $SP_{max}$ para o ponto de operação <i>very loose</i>	119

# SUMÁRIO

	INTRODUÇÃO	14
1	FÍSICA DE ALTAS ENERGIAS	18
1.1	Modelo Padrão de Partículas Elementares	18
1.1.1	Interações fundamentais	21
1.1.1.1	Interação forte	21
1.1.1.2	Interação eletrofraca	22
1.1.2	Mecanismo de Higgs	23
1.1.3	Além do Modelo Padrão	23
1.2	Chuveiros eletromagnético e hadrônico	24
1.3	A importância dos elétrons na Física de Altas Energias	25
1.4	Objeto Boosted	26
2	O CERN, O LHC E O EXPERIMENTO ATLAS	29
2.1	CERN e LHC	29
2.2	Os experimentos do LHC	31
2.3	O experimento ATLAS	32
2.3.1	Sistema de coordenadas do ATLAS	32
2.3.2	Detector de traços ou detector interno	34
2.3.2.1	Pixel Detector	35
2.3.2.2	Semicondutor Tracker (SCT)	36
2.3.2.3	Transition Radiation Tracker (TRT)	36
2.3.3	Sistema de Calorimetria	36
2.3.3.1	Pré-amostrador (PS)	37
2.3.3.2	Calorímetro Eletromagnético (ECAL)	38
2.3.3.3	Calorímetro Hadrônico (HCAL)	39
2.3.3.4	Calorímetro Hadrônico de Telhas (TileCal)	39
2.3.3.5	Tampas do HCAL (HEC) e Forward Calorimeter (FCAL)	41
2.3.4	$\underline{\text{Sistema de Muons}}$	42
2.3.4.1	Tubos de deriva monitorados (MDT) e camada de tiras de catodo (CSC) .	42
2.3.4.2	Camadas de placas resistivas (RPC) e <i>Thin-gap chambers</i> (TGC)	43
2.3.5	Sistema de aquisição de dados e sistema de filtragem ( <i>Trigger</i> )	44
2.3.5.1	Primeiro nível do sistema de filtragem (L1)	46
2.3.5.2	Sistema de filtragem de alto nível (HLT)	48
2.4	Reconstrução dos objetos físicos pelo ATLAS	50
2.4.1	Reconstrução dos elétrons	50
2.4.1.1	Método Tag and Probe	52
2.5	Atualizações da Run 3	53

2.5.1	$\underline{\text{L1Calo}}$	53
2.5.2	<u>HLT Calorimeter (HLTCalo)</u>	54
3	APRENDIZADO DE MÁQUINA	56
3.1	Redes Neurais	56
3.1.1	Neurônio artificial	57
3.1.2	<u>Perceptron</u>	57
3.1.3	<u>Multi Layer Perceptron</u>	59
3.1.4	<u>Algoritmo RPROP</u>	61
3.1.5	<u>Algoritmo ADAM</u>	62
3.1.6	Validação Cruzada	63
4	ALGORITMO DOS ANÉIS DE ENERGIA ( <i>RINGERS</i> )	64
4.1	NeuralRinger	64
4.2	Histórico do <i>NeuralRinger</i>	69
5	VARIÁVEIS DE SHOWER SHAPE	72
6	INEFICIÊNCIA NA IDENTIFICAÇÃO DOS ELÉTRONS BO-	
	OSTED	76
7	FUSÃO DE INFORMAÇÃO	78
7.1	Classificação: dados de entrada	78
7.2	Classificação: Dasarathy	79
7.3	Classificação: nível abstrato	80
7.4	Classificação: Joint Directors of Laboratories (JDL)	81
7.5	Classificação: arquitetura de fusão	82
7.6	Escolha do modelo de fusão de informação	84
8	MÉTODO UTILIZADO	87
9	DADOS E RESULTADOS	88
9.1	Dados reais e simulados	88
9.2	Resultados	89
9.2.1	$\underline{\text{Tabelas de } P_D}$	90
9.2.2	Curvas de eficiência ( <i>Turn ons</i> )	93
9.2.3	Análise de quadrante	96
	CONCLUSÃO E TRABALHOS FUTUROS	104
	REFERÊNCIAS	106
	$\mathbf{AP\widehat{E}NDICE} \ \mathbf{A}$ – Tabelas de probabilidade de detecção 1	L16
	<b>APÊNDICE B</b> – Curvas de eficiência	120

### INTRODUÇÃO

Todo sistema de aquisição de dados deve ser adequado ao seu ambiente de atuação, ou seja, ele deve apresentar as características necessárias para desempenhar a sua tarefa da forma mais eficiente possível. Em um ambiente com uma alta frequência de entrada de dados, esse sistema de aquisição de dados também precisa utilizar um filtro. Considerando que os dados adquiridos apresentam medidas que levam a eventos de interesse os quais são raros, como em um ambiente da Física de Altas Energias, esse filtro deve apresentar tomadas de decisões que privilegiem os dados que indiquem tais eventos de interesse.

Um filtro *online* serve justamente para o caso descrito acima, ele deve realizar sua filtragem durante a aquisição de dados tendo que tomar decisões que privilegiem os eventos de interesse, utilizando o menor custo de memória e processamento possível, que apresente a melhor eficiência no seu desempenho, pois não existe a possibilidade de armazenar toda a informação. Os eventos não selecionados são descartados, enquanto os selecionados são armazenados para serem analisados posteriormente (*offline*).

Em experimentos de Física de Altas Energias, como os experimentos do *Large Hadron Colider* (LHC), onde colidem feixes de prótons a cada 25 ns gerando uma quantidade de informação da ordem de 70 TB/s, é imprescendível que haja um filtro *online* que determine o que será armazenado ou não (European [...], 2023e). Ambientes como esse, podem apresentar uma divisão de seu espaço de fase formando *ensembles* que auxiliam a tomada de decisão do filtro com base em sua granularidade (Freund, 2018).

Em ambientes com muitos sensores oriundos de detecções distintas, os dados que são gerados podem ser utilizados de forma complementar para que haja um melhor aproveitamento da obtenção da informação (Castanedo, 2013). A associação de dados para esse processo é chamada de fusão de dados. Nos casos em que os dados já foram pré-processados, ou seja, não são dados brutos, denominamos essa combinação de fusão de informação (Castanedo, 2013).

#### Motivação

Atualmente, o LHC é o maior acelerador de partículas em operação no mundo, localizado no *Centre Européene pour la Rechèrche Nucleaire* (CERN) em Genebra, na Suíça (European [...], 2023e). Ele é um acelerador circular com circunferência de aproximadamente 27 km. O LHC possui 4 experimentos de grande porte, dentre eles, o ATLAS (*A Toroidal LHC Apparatus*) (ATLAS Collaboration, 2008) onde este trabalho foi realizado. O ATLAS e o *Compact Muon Solenoid* (CMS) (CMS Collaboration, 2008) são experimentos de propósito geral no LHC, ou seja, eles têm como objetivo investigar todos os fenômenos físicos envolvidos nas colisões próton-próton (chumbo-chumbo ou chumbo-próton) nas energias do LHC. Os dois experimentos anunciaram conjuntamente a descoberta do bóson de Higgs em 2012 (European [...], 2024b), previsto por Peter Higgs e Fraçois Englert, que receberam o prêmio Nobel de Física em 2013<sup>1</sup>.

Atualmente, o LHC encontra-se em sua terceira tomada de dados (Run 3) com energia do centro de massa de 13,6 TeV, sendo que a primeira e a segunda tomada de dados apresentavam, respectivamente, 8 TeV (também tiveram colisões a 2,76 TeV por núcleon e 7,0 TeV, além das colisões de chumbo) e 13 TeV. Com isso, sua luminosidade<sup>2</sup> (ATLAS Collaboration, 2016c) vem aumentando, necessitando-se de melhores técnicas de detecção.

Devido à alta taxa de informação (aproximadamente 70 TB/s) que é coletada pelos detectores do ATLAS, ele apresenta dois sistemas de filtragem *online* (*On-line Trigger*): o Primeiro Nível de Filtragem (L1) em *hardware* e o Alto Nível de *Trigger* (HLT, *High Level Trigger*) em *software* (Freund, 2018). Em ambos, são utilizadas técnicas de reconhecimento de padrões.

As colisões no LHC geram partículas instáveis, sendo que muitas decaem em elétrons ou em pares elétron-pósitron (Hanagaki *et al.*, 2022). Os elétrons deixam assinaturas em dois detectores do ATLAS, os calorímetros (no caso, o eletromagnético) que mede sua energia por meio de sua absorção e o detector de traços que mede suas trajetórias. Nos calorímetros sua absorção ocorre através de interações em sequência, ou seja, cascatas que são chamadas de chuveiros eletromagnéticos. Um elétron, ao atravessar uma placa de chumbo do calorímetro eletromagnético, irradia um fóton que decai em um par elétron-pósitron em que o pósitron interage com um elétron do material e faz o processo continuar até o limiar de energia no qual esses processos físicos não possam mais ocorrer. Mais detalhes podem ser vistos na seção 2.3.3. Já no detector de traços, por ser formado por silício, há a ionização do material permitindo assim determinar sua trajetória.

O HLT do ATLAS utiliza a informação proveniente dos calorímetros para realizar a identificação de elétrons. O algoritmo *NeuralRinger* (Seixas *et al.*, 1996) está sendo utilizado para identificar elétrons desde 2017. Este algoritmo utiliza redes neurais especialistas em *ensembles* divididos em função da posição e da energia da partícula para maximizar sua eficiência. Ele cria anéis concêntricos em torno da posição da partícula mais energética incidente em todas as camadas dos calorímetros e mede sua energia absoluta (Pinto, 2022).

<sup>&</sup>lt;sup>1</sup> O bóson de Higgs também foi previsto por Robert Brout, porém ele faleceu em 2011, não recebendo o prêmio (Mecanismo..., 2024).

 $<sup>^2</sup>$  A luminosidade está definida na seção 2.1 na equação 7.

Além dos anéis do *NeuralRinger*, há variáveis físicas que medem outras informações dos chuveiros como largura ou frações de energia entre as camadas, essas variáveis são conhecidas como variáveis de *shower shape* (Mistry; Thompson; Williams, 2016). Elas podem ser utilizadas na mesma etapa do *NeuralRinger*, porém estudos já apontaram que sozinhas, elas não são mais eficazes que o *NeuralRinger* (Freund, 2018).

Em 2019, o NeuralRinger apresentou ineficiências consideráveis em relação aos elétrons que apresentam um alto momento transverso com uma distância relativa pequena ( $\Delta R$ , uma distância do espaço de fase que sugere a distância do ponto de interação de duas partículas no detector, dada pela equação 14). Uma estratégia para resolver esse problema foi a diminuição de anéis do NeuralRinger (de 100 anéis para 50 anéis) que obteve resultados promissores, porém pode-se explorar a utilização das variáveis de shower shape que estão disponíveis usando modelos de fusão de informação.

#### Objetivo

O objetivo deste trabalho é explorar as variáveis de shower shape em modelos de fusão de informação combinadas com o NeuralRinger para a criação de um novo filtro online e compará-lo com os modelos do NeuralRinger que estão disponíveis para o ATLAS. O ensemble é dividido em 25 regiões de energia transversa por  $\eta$ , cinco regiões de  $E_T$  por cinco regiões de  $\eta$ . Cada região utiliza modelos de fusão distribuída com redes neurais do tipo Percepton de Múltiplas Camadas (MLP).

#### **Resultados obtidos**

Os dados experimentais utilizados são de colisões próton-próton coletados em 2017 e os dados simulados de Monte Carlo foram gerados em 2016 e 2021, eles serão descritos no capítulo 9. O espaço de fase (*ensemble*) apresenta 25 regiões com uma rede neural para cada um, dividido por  $\eta \in E_T^3$ . Os modelos de fusão apresentaram bons resultados em algumas regiões em relação ao falso alarme<sup>4</sup> ( $P_F$ ), mostrando sua redução quando comparados com os modelos que usam somente o *NeuralRinger*, permaneceram dentro da margem de erro de 1 $\sigma$  nas outras regiões.

Os resultados serão apresentados no capítulo 9. Nele, temos as tabelas de probabilidade de detecção  $(P_D)$  que também contém o índice de falso alarme. Na sequência, temos as curvas de eficiência (*turn ons*) e por último a comparação entre os modelos com

 $<sup>^3</sup>$  A tabela 2 apresenta a divisão do espaço de fase.

<sup>&</sup>lt;sup>4</sup> Também conhecido como eficiência de *background* ou eficiência de jatos, neste caso.

a análise de quadrante, mostrando que a fusão de informação apresenta vantagens para o *trigger* HLT.

Os resultados encontrados neste trabalho foram debatidos em diversos grupos de pesquisa incluindo pesquisadores de universidades como UERJ, UFRJ, COPPE/UFRJ, UFBA, UFJF, *Sorbonne* (França), entre outras.

#### Organização da Dissertação

O capítulo 1 faz uma introdução da Física de Altas Energias enquanto o capítulo 2 mostra como ela pode ser estudada através da apresentação do CERN, LHC e o experimento ATLAS. O capítulo 3 traz uma introdução sobre o aprendizado de máquina e na sequência os capítulos 4 e 5 descrevem o *NeuralRinger* e as variáveis de *shower shape*. O capítulo 6 discute o problema da ineficiência do *NeuralRinger* para identificar os elétrons *Boosted* e o capítulo 7 apresenta a fusão de informação com suas técnicas e métodos. O capítulo 8 apresenta o método utilizado. O capítulo 9 descreve os dados utilizados e mostra os resultados obtidos seguido pela conclusão e pelos anexos.

#### 1 FÍSICA DE ALTAS ENERGIAS

A Física de Altas Energias é um ramo da Física que estuda as propriedades das partículas elementares e suas interações. Até o presente momento, o Modelo Padrão de Partículas Elementares (ou somente Modelo Padrão) é o melhor modelo teórico para descrever as partículas elementares e suas interações.

#### 1.1 Modelo Padrão de Partículas Elementares

O Modelo Padrão de Partículas Elementares (MP) (Gaillard; Grannis; Sciulli, 1998) foi desenvolvido nas décadas de 50, 60 e 70, ele é uma estrutura teórica que apresenta uma compreensão das partículas elementares e das interações fundamentais. O MP descreve três das quatro interações fundamentais, a eletromagnética, a forte e a fraca (Gaillard; Grannis; Sciulli, 1998). Além disso, há fenômenos que não são explicados pelo MP, como a matéria escura, a energia escura e a assimetria bariônica (diferença entre matéria e antimatéria) (Chiedde, 2023).

Na Física de Partículas Elementares, a massa das particulas é definida em unidades de energia, lembrando que Einstein nos dá  $E = mc^2$ , portanto se quisermos a massa em unidades usuais (gramas e seus submúltiplos) devemos dividir o valor dado pela velocidade da luz ao quadrado. A energia é dada em unidades de elétron-volt, eV, e seus múltiplos MeV, GeV, TeV, ou seja, Mega, Giga e Tera eletron-volts respectivamente. Por definição, um elétron-volt é a quantidade de energia cinética ganha por um único elétron quando acelerado por uma diferença de potencial de um Volt, no vácuo.

As partículas do MP são classificadas como férmions ou bósons. Os férmions obedecem à estatistica de Fermi-Dirac (Sears; Salinger, 1979), ou seja, obedecem ao Princípio de Exclusão de Pauli. Os bósons seguem a estatística de Bose-Einstein(Sears; Salinger, 1979).

Uma propriedade importante que difere os férmions dos bósons é o spin, momento magnético intrísico da partícula que pode apresentar valores inteiros ou semiinteiros (Griffiths, 2008). O spin apresenta seu valor numérico em unidades da constante de Planck dividida por  $2\pi$  ( $\hbar$ ). Os férmions apresentam spin semi-inteiro e são os constituintes da matéria, sendo classificados como quarks e léptons, que são, por sua vez, organizados em três gerações ou famílias de massa crescente, cada uma com um par de quarks e um par de léptons. Os bósons apresentam spin inteiro e podem ser formados por partículas cujos spins somados formam um número inteiro ou podem ser bosóns mediadores das interações. Há também o bóson de Higgs, que apresenta spin 0 e é responsável por dar massa a todas as partículas do MP através do Mecanismo de Higgs. Pode ser visto na figura 1, um esquema do MP com os férmions e bósons e seus respectivos spins.



Figura 1 - Modelo Padrão de Física de Partículas

Fonte: Campos, 2023, p. 18.

Os quarks são os constituintes dos hádrons, que podem ser formados por três quarks chamados de bárions, ou por um par quark-antiquark, chamados de mésons. Os prótons e nêutrons são bárions, o próton apresenta dois quarks up e um quark downenquanto o nêutron tem dois quarks down e um quark up. O méson  $\pi$  é formado pelos quarks  $u - \overline{d}(\pi^+), d - \overline{u}(\pi^-)$ , uma combinação  $u - \overline{u}$  e  $d - \overline{d}(\pi^0)^5$  (Freire, 2010). Os quarks apresentam cargas elétricas fracionadas, por exemplo, o quark up apresenta carga elétrica de  $+\frac{2}{3}$  da carga do elementar enquanto o quark down possui carga elétrica de  $-\frac{1}{3}$  da carga do elementar, o que faz o próton ter carga elétrica de +1 da carga do elementar e o nêutron carga elétrica nula, ou seja, a carga elétrica dos quarks definem a carga elétrica dos hádrons (Griffiths, 2008).

Considerando o Princípio de Exclusão de Pauli, hádrons formados por 3 quarks iguais não poderiam existir, por isso, foi proposta uma nova propriedade denominada carga de cor (Griffiths, 2008). Os quarks podem apresentar até três cargas de cor (verde, vermelho e azul), sendo que as partículas formadas por quarks apresentam cor neutra, ou seja, as três cores juntas resultam na cor branca (ou neutra) e os quarks que formam os mésons apresentam uma cor e uma anticor (Assis, 2021). Há 6 tipos de quarks: *up*, *down*, *strange*, *charm*, *top*, *bottom*.

<sup>&</sup>lt;sup>5</sup> Em 2015, no LHC (CERN) foram detectadas duas partículas com cinco quarks ou simplesmente pentaquark,  $P_c(4450)^+$  e  $P_c(4380)^+$ . Em 2019, foi descoberta mais um pentaquark,  $P_c(4312)^+$  (European [...], 2019).

O elétron é classificado como lépton. Além dele, temos o múon ( $\mu$ ) e o tau ( $\tau$ ) que são partículas que apresentam o mesmo comportamento do elétron (relativamente às interações fundamentais), mas com massa bem mais alta (Griffiths, 2008). O elétron, o múon e o tau possuem seu neutrino correspondente, ou seja, temos o neutrino do elétron, o neutrino do múon e o neutrino do tau. Essa nomenclatura se deve à interação fraca, quando um neutrino do elétron interage com a matéria ocorre a troca de um bóson W, resultando um elétron (Griffiths, 2008). Os neutrinos possuem carga elétrica nula e uma massa muito pequena.

Para cada partícula temos sua correspondente antipartícula que apresenta carga elétrica, número bariônico e número leptônico invertidos, por exemplo, a primeira antipartícula descoberta foi a antipartícula do elétron, chamada de pósitron, que possui carga elétrica positiva e número leptônico -1, enquanto o elétron tem carga elétrica de negativa e número leptônico +1. O número bariônico é definido segundo a equação 1:

$$B = \frac{1}{3}(n_q - n_{\bar{q}}) \tag{1}$$

onde B é o número bariônico,  $n_q$  é o número de quarks e  $n_{\bar{q}}$  é o número de antiquarks. O número leptônico é definido pela soma da quantidade de léptons (+1) e antiléptons (-1). Os quarks apresentam número bariônico  $+\frac{1}{3}$  enquanto os antiquarks  $-\frac{1}{3}$ , ambos tem número leptônico nulo. Os léptons e antiléptons apresentam número bariônico nulo e seu número leptônico é 1 e -1, respectivamente. O neutrino, que possui carga elétrica neutra, difere de seu par de antimatéria pelo número leptônico que só pode ser observado pelos produtos de sua interação, por exemplo, no decaimento Beta, onde o nêutron decai e tem como resultado final um próton, um elétron e um antineutrino  $(n \rightarrow p + e^- + \bar{\nu})$ , sabe-se que é um antineutrino devido a conservação do número leptônico, que antes da interação era 0 (com apenas o nêutron) e depois se conserva com o +1 do elétron e o -1 do antineutrino. Quando uma partícula e sua correspondente antipartícula se encontram, há aniquilação das duas produzindo energia pura, ou seja, fótons. A figura 2 mostra a aniquilação de um elétron com um pósitron gerando fótons.

Os bósons vetorias ou bósons de calibre são partículas transportadoras (ou mediadoras) das interações fundamentais, cada interação tem sua carga correspondente:

- a interação eletromagnética necessita de uma carga elétrica pela troca de uma partícula neutra, sem massa de spin 1, o fóton;
- a interação forte requer uma carga de cor, sendo a partícula mediadora o glúon que não tem massa e spin 1;
- a interação fraca tem como mediadores, dois bósons massivos de spin 1, o W<sup>±</sup> que apresenta carga elétrica positiva ou negativa e o Z<sup>0</sup> com carga elétrica nula.

Figura 2 - Aniquilação de um elétron e de um pósitron



Fonte: Annihilation, 2011. Adaptado pelo autor.

A interação fraca é a única que não é invariante sob transformações de paridade, ou seja, transformações relacionadas a coordenadas do tipo levogiro (mão esquerda) e dextrogiro (mão direita) (Griffiths, 2008). As partículas podem ser divididas em partículas de mão esquerda, que têm uma polarização de spin em direção oposta ao seu movimento e partículas de mão direita, que têm polarização de spin na mesma direção ao seu movimento (Griffiths, 2008). Os neutrinos são partículas que são exclusivamente de mão esquerda. O MP não descreve a interação gravitacional, seu mediador é o gráviton que não foi detectado até o momento (Chiedde, 2023).

#### 1.1.1 Interações fundamentais

Há quatro interações fundamentais: interação forte, interação fraca, interação eletromagnética e interação gravitacional. As interações fraca e eletromagnética foram unificadas em uma única interação. A interação gravitacional não será discutida devido a sua baixa intensidade em relação as outras interações, visto que a massa das partículas é pequena.

#### 1.1.1.1 Interação forte

A interação forte é explicada pela Cromodinâmica Quântica (QCD). Os glúons apresentam cargas de cor (vermelho, verde e azul) e anticor (antivermelho, antiverde e

antiazul), onde suas combinações levam a 8 configurações de glúons. Por apresentarem cargas de cor, os glúons podem interagir com eles mesmos, onde o acoplamento de glúons entre si, dá origem a vértices adicionais além do fundamental de quark-glúon.

A distâncias menores que o diâmetro de um próton, a força de acoplamento entre os quarks diminui e eles se comportam como partículas livres, ou seja, temos uma liberdade assintótica. A medida que a distância entre os quarks aumenta, a força de acoplamento se intensifica, o que impede seu isolamento. Dessa forma, não há quarks livres, pois eles sempre estarão confinados dentro dos hádrons.

#### 1.1.1.2 Interação eletrofraca

A teoria de Glashow-Weinberg-Salam (GWS) ou teoria eletrofraca foi desenvolvida com dados experimentais de interações fracas de corrente carregada (Glashow; Weinberg, 1977; Bilenky; Hošek, 1982). Essa teoria unificou a interação eletromagnética com a interação fraca. Ela utiliza a teoria de calibre, que descreve as interações entre os campos de calibre eletrofracos sem alterar a dinâmica do sistema, ou seja, as interações surgem de simetrias. Simetria é uma invariância de um objeto ou sistema físico frente a uma transformação (Moreira, 2019).

A simetria de calibre eletrofraca combina as constantes de acoplamento da simetria de isospin fraca com a simetria de fase de hipercarga fraca dando origem a quatro bósons mediadores, que são os bósons de calibre,  $\gamma$ ,  $Z^0$ ,  $W^+$  e  $W^-$ . O isospin fraco é um número quântico relacionado à parte carregada da interação fraca, partículas com isospin fraco semi-inteiro interagem com os bósons carregados da interação fraca enquanto as partículas com isospin fraco 0, não (Weinberg, 1967; Weak..., 2024). A hipercarga fraca  $(Y_W)$  é um número quântico que relaciona a carga elétrica com o terceiro componente do isospin fraco  $(T_3)$  (Hipercarga..., 2023) sua definição está na equação 2:

$$Y_W = 2(Q - T_3)$$
(2)

Os bósons de calibre não podem ter massa, pois se tiverem, levariam a uma violação local da invariância de calibre, porém sabe-se que os bósons da interação fraca e os férmions têm massa (Glashow; Iliopoulos; Maiani, 1970; Chiedde, 2023). Devido a isso, foi introduzido um mecanismo de quebra espontânea de simetria eletrofaca, também conhecido por mecanismo de Higgs para dar massa as partículas.

#### 1.1.2 Mecanismo de Higgs

A teoria eletrofraca e a QCD permitem somente a existência de partículas sem massa, no entanto, o modelo de Brout-Englert-Higgs de 1964 (Englert; Brout, 1964; Higgs, 1966) solucionou o problema das massas com a adição do mecanismo de Higgs. Ele apresenta a quebra espontânea de simetria separando as simetrias locais das simetrias do vácuo quântico. O mecanismo de Higgs gera um campo de auto-interação  $\phi$  que possui estados degenerados com valor esperado para o vácuo diferente de zero. O grau de liberdade restante torna-se um campo escalar massivo dando origem ao bóson de Higgs,  $H^0$ , que ganha acoplamento com os férmions e bósons de gauge sendo esse acoplamento proporcional à massa dos férmions e bósons aos quais se acopla (Guralnik; Hagen; Kibble, 1964; Chiedde, 2023). O bóson de Higgs foi a última partícula fundamental encontrada em 2012 no CERN (European [...], 2024b). A figura 1 apresenta um esquema do MP.

#### 1.1.3 Além do Modelo Padrão

O MP não prevê a massa dos neutrinos leves, entretanto os neutrinos oscilam (Kajita *et al.*, 2016), ou seja, há mudança de sabor entre neutrinos e por consequência eles apresentam massa, isso foi comprovado por Takaaki Kajita (Kajita, 2015) e Arthur McDonald (McDonald, 2015) resultando no prêmio Nobel de 2015. A teoria da oscilação de neutrinos leva em consideração que existem mais três neutrinos físicos com massas bem determinadas e os três neutrinos conhecidos que interagem com os léptons são superposições de estados desses neutrinos físicos. Por exemplo, o neutrino do elétron pode ser definido pela equação 3:

$$\nu_e = U_{e1}\nu_1 + U_{e2}\nu_2 + U_{e3}\nu_3 \tag{3}$$

onde  $U_{e1}$ ,  $U_{e2}$  e  $U_{e3}$  são os coeficientes de mistura dos respectivos neutrinos físicos,  $\nu_1$ ,  $\nu_2$ e  $\nu_3$  (Valdiviesso; Guzzo, 2005). A oscilação dos neutrinos não é descrita pelo MP e como dito anteriormente, há outros fenômenos que não são descritos pelo MP como matéria e energia escuras e devido a isso, há modelos que tentam resolver alguns desses problemas apresentando novas partículas ou não, Esses modelos são chamados de Modelos além do MP.

#### 1.2 Chuveiros eletromagnético e hadrônico

Os experimentos da Física de Altas Energias conseguem investigar os chuveiros de partículas através da utilização de calorímetros. Após a colisão do feixe de partículas no centro dos detectores, as partículas com altas energias irão colidir com o material dos detectores, dentre eles os calorímetros, gerando chuveiros eletromagnéticos ou hadrônicos dependendo do material dos detectores, da partícula de incidência e de sua energia. Os calorímetros registram a energia depositada das partículas através da energia oriunda dos chuveiros. Mais detalhes sobre os calorímetros podem ser vistos na seção 2.3.3.

Um chuveiro de partículas é uma cascata de partículas secundárias oriundas de uma interação de uma partícula com alta energia com a matéria. As novas partículas produzidas apresentam menos energia que a primária e cada uma delas interage dando origem a outras partículas e assim por diante até que não haja mais energia para se continuar o processo. Existem dois tipos de chuveiros: os eletromagnéticos que vêem de partículas que interagem principalmente pela interação eletromagnética como fótons e elétrons, e os hadônicos que são oriundos de partículas que interagem principalmente pela interação forte como hádrons (Tavernier, 2010; Particle..., 2023). A figura 3 apresenta uma ilustração de um chuveiro eletromagnético e de um hadrônico.

O chuveiro eletromagnético inicia quando um fóton, pósitron ou elétron de alta energia interage com o material do detector. Se a energia das partículas estiver acima de alguns MeVs, o fóton vai interagir principalmente pela produção de pares elétron-pósitron, devido ao efeito fotoelétrico e ao espalhamento Compton serem quase irrelevantes nessa faixa de energia, enquanto os elétrons e os pósitrons irão emitir fótons, em um processo denominado *bremsstrahlung* (radiação de freamento, em que uma partícula carregada emite radiação eletromagnética devido à interação com o material do detector ou a um campo eletromagnético) (Perkins, 1972). Com a continuação desses processos, há uma cascata de partículas de energia decrescente até que a energia dos fótons caia abaixo do limite da produção de pares e a dos elétrons/pósitrons caia abaixo do processo de *bremsstrahlung* (Assis, 2021; Particle..., 2023). A profundidade do chuveiro pode ser determinada pela equação 4:

$$X = X_0 \frac{\ln \frac{E_0}{E_c}}{\ln 2} \tag{4}$$

onde  $X_0$  é o comprimento de radiação na matéria,  $E_0$  é a energia inicial da partícula e  $E_c$  é a enegia crítica que pode ser definida como a energia de igualdade das taxas de ocorrência de *bremsstrahlung* e de ionização (Particle..., 2023).

No chuveiro hadrônico de partículas, cerca de metade da energia hadrônica incidente é transmitida para partículas secundárias adicionais e o restante é consumido na produção de píons lentos e em outros processos. Os chuveiros hadrônicos demoram mais tempo para se desenvolver do que os chuveiros eletromagnéticos e eles ocorrem por produção de hádrons, desexcitação nuclear e principalmente decaimentos de píons e múons. A energia dos píons neutros é dissipada por chuveiros eletromagnéticos (Assis, 2021; Particle..., 2023).

Figura 3 - Ilustração de um chuveiro eletromagnético e de um hadrônico



Legenda: Esquerda: chuveiro eletromagnético. Direita: chuveiro hadrônico. Fonte: Assis, 2021, p. 83. Adaptado pelo autor.

#### 1.3 A importância dos elétrons na Física de Altas Energias

O elétron foi a primeira partícula elementar descoberta (por Joseph John Thomson em 1897) dando início a Física de Partículas Elementares. Várias partículas têm seus decaimentos resultantes em elétrons, por isso o elétron é de extrema importância para qualquer experimento de Física de Altas Energias.

As partículas que podem decair em elétrons e pósitrons são (Freire, 2010; Assis, 2021; Brendlinger, 2016; Whalen, 2015; Theveneaux-Pelzer, 2011):

- os bósons:  $\gamma^{6} \to e^{+}e^{-}, Z^{0} \to e^{+}e^{-}, W^{-} \to e^{-}\overline{\nu}, W^{+} \to e^{+}\nu;$
- os mésons:  $J/\Psi \to e^+e^-, \ \Upsilon \to e^+e^-$ , entre outros;
- decaimentos indiretos com resultante em elétrons:  $H \to Z^0 Z^0 \to e^+ e^- e^+ e^-$ , os léptons mais pesados que o elétron ( $\mu \to e^- \overline{\nu}_e \nu_\mu$  e  $\tau \to e^- \overline{\nu}_e \nu_\tau$ ), os quarks, como exem-

<sup>&</sup>lt;sup>6</sup> O fóton é uma partícula estável, porém ele faz produção de pares que ocorre quando um fóton com energia acima do dobro da massa do elétron passa por um material de alto número atômico, como o chumbo.

plo o  $top \to W^+b$ , ou o  $b \to W^-c$  e o  $c \to W^+d$  onde os  $W^+(W^-) \to e^+(e^-)\nu(\overline{\nu})$ , entre outros.

Fora o decaimento das partículas, há processos físicos que emitem energia pura como o *bremsstrahlung*, ou seja, fótons e esses fótons são convertidos em pares elétronpósitron. A partir desses decaimentos e dos processos físicos, percebe-se a relevância do elétron para o ATLAS, o elétron é uma das partículas mais importantes a serem detectadas, por isso, ter bons sistemas de detecção e identificação no sistema de aquisição de dados e de filtragem é de vital importância.

Além da detecção de elétrons, há os casos particulares em que é necessário identificar elétrons isolados devido ao decaimento da partícula estudada, como por exemplo, o W, que no decaimento  $W^- \rightarrow e^- \overline{\nu}$  apresenta apenas uma partícula que pode ser detectada, o elétron. Para isso, é necessário aplicar cortes na soma total de eneregia e de momento em torno do elétron a fim de considerá-lo isolado.

Algo bastante comum em experimentos de Física de Altas Energias são partículas produzidas na colisão dos feixes que possuem vida média muito pequena, decaindo logo após serem produzidas. Como possuem alto momento, seus produtos de decaimento tendem a estar muito colimados, produzindo chuveiros superpostos nos calorímetros. Os sistemas de filtragem precisam estar atentos a esses objetos, que serão tratados na seção 1.4, a seguir.

#### 1.4 Objeto Boosted

No decaimento de partículas, há a conservação do momento. Se a partícula que irá decair apresentar uma alta velocidade no referencial do laboratório, as partículas geradas no decaimento continuarão com alto momento em relação à direção de movimento da partícula mãe até interagirem com o material do detector (Vos, 2009). O objeto *Boosted* é uma partícula que viaja com alta velocidade em relação ao laboratório e seu momento é muito maior que a massa da partícula. A figura 4 apresenta o decaimento de um objeto *Boosted*.

Para duas partículas provenientes do decaimento de uma partícula *Boosted*, a distância entre seus 2 produtos de decaimento no espaço da rapidez e do ângulo azimutal  $(y, \phi)$  é dada pela equação 5:

$$\Delta R \approx \frac{2m}{p_T} \tag{5}$$

onde m é a massa da partícula (partícula mãe) que decairá e  $p_T$  o seu momento transverso (plano XY). Como o momento transverso é muito maior que a massa da partícula, a

distância,  $\Delta R$  será muito pequena e o ângulo entre as duas partículas também será bem pequeno, podendo ocasionar, ao interagir com um detector, dois chuveiros de partículas parcialmente superpostos (Schätzela, 2015). Esse pode ser o caso de um par elétronpósitron proveniente do decaimento de uma partícula, ou mesmo 2 elétrons produzidos na interação ou em decaimentos diferentes (de dois W, por exemplo). Quando atingem o calorímetro eletromagnético geram chuveiros parcialmente superpostos que podem ser identificados como jatos, visto que não apresentam o comportamento de um chuveiro produzido por um elétron isolado. Os algoritmos usados no trigger precisam ser capazes de identificar esses casos, evitando a perda de eventos de interesse.





Legenda: Esquerda: decaimento da partícula rosa em duas partículas azuis menores. Direita: O mesmo decaimento, mas dessa vez, a partícula rosa apresenta uma alta velocidade no referencial do laboratório, um objeto "boosted".

Fonte: Vos, 2009.

Supondo que o comportamento boosted ocorra a  $\Delta R < 0, 4$  e utilizando a equação 5, temos que o efeito boosted ocorre com os produtos de decaimento das partículas que apresentam um momento transverso maior que 5 vezes a sua massa aproximadamente. Alguns exemplos de partículas em que esse fenômeno pode acontecer são:  $Z^0$ , m =91.1876  $\pm$  0.0021 GeV (Tanabashi *et al.*, 2019); Higgs ( $H \rightarrow Z^0 Z^0$  e cada  $Z^0 \rightarrow e^+e^-$ ) (Brendlinger, 2016; Whalen, 2015),  $m = 125, 10 \pm 0, 14$  GeV;  $J/\Psi$  (Theveneaux-Pelzer, 2011),  $m = 3096, 900 \pm 0,006$  MeV (Tanabashi *et al.*, 2018a);  $\Upsilon$ ,  $m = 9460, 30 \pm 0, 26$ MeV (Tanabashi *et al.*, 2018b); há outros mésons pesados que também podem decair em pares de elétron-pósitron (Nakamura *et al.*, 2010). Há estudos relacionados à procura por novas partículas, como o Z' (Assis, 2021), utilizando elétrons boosted (Herwig *et al.*, 2023), dada a possibilidade de sua forma de decaimento em um bóson Z e um bóson de Higgs, com o Higgs decaindo em dois bósons Z, cada bóson Z decaindo no par elétron-pósitron, resultando em um evento com 6 elétrons (CMS Collaboration, 2021). Além disso, há casos em que dois elétrons no mesmo evento, que não apresentam nenhuma correlação e não vem de um decaimento, podem apresentar o comportamento *boosted* dificultando a sua reconstrução.

Há também objetos *boosted* em jatos, embora este trabalho não utilize jatos *boosted*, pois partículas que decaem nesses objetos estão sujeitas ao mesmo processo, por exemplo, o Higgs decaindo em dois quarks b (b e antib) ou o decaimento de uma partícula em pares de top-antitop como o Z' (Vos, 2014). A figura 5 apresenta o decaimento de uma partícula em dois jatos e depois em dois jatos *boosted*, no caso dos elétrons no calorímetro eletromagnético, o efeito é parecido ao que está apresentado nessa figura. A detecção desses dois jatos, no caso *boosted* pode ser interpretada como sendo de um único jato largo (ou gordo) e a reconstrução convencional, por exemplo de um bóson W decaindo em jatos, irá falhar não reconstruindo a massa da partícula (Schätzela, 2015).

Figura 5 - Decaimento da partícula X em jatos



Legenda: Nesta figura temos uma partícula X que decai em 2 jatos. Na figura superior vemos o decaimento no sistema do centro de massa da partícula X. Na figura inferior vemos o mesmo decaimento, mas no referencial do laboratório. Em inglês, dizemos que esse é o referencial boosted. Acima: decaimento da partícula em dois jatos no referencial do centro de massa da partícula mãe. Abaixo: O mesmo decaimento, mas dessa vez, a partícula apresenta uma alta velocidade no referencial do laboratório, um objeto "boosted". O "Z"significa a fração de momento de um dos jatos.

Fonte: Schätzela, 2015, p. 3.

#### 2 O CERN, O LHC E O EXPERIMENTO ATLAS

#### 2.1 CERN e LHC

O CERN (European [...], 2023c) é o Laboratório Europeu de Física de Partículas fundado em 1954 e localizado na fronteira entre a França e a Suíça. O nome do CERN era *Conseil Européen pour la Recherche Nucléaire*, ou Centro Europeu para Pesquisas Nucleares. Com o tempo, a pesquisa ali desenvolvida no CERN passou a ser em Física de Partículas, por isso é comum utilizarem o nome *European Laboratory for Particle Physics*, mantendo a sigla CERN. Ele possui o maior acelerador de partículas em operação do mundo, o LHC.

O LHC, *Large Hadron Collider* ou Grande Colisor de Hádrons (European [...], 2023e), tem aproximadamente 27 km de circunferência, localizado a cerca de 100 m abaixo da superfície e ele apresenta quatro experimentos de grande porte, o ALICE (European [...], 2023a), LHCb (European [...], 2023g), o CMS (European [...], 2023d) e o ATLAS (European [...], 2023b), sendo os dois últimos de propósito geral. A figura 6 apresenta o complexo de aceleradores do CERN. Os feixes de partículas são colididos no centro desses experimentos, onde há diversos detectores concêntricos para registrar as partículas produzidas na colisão (menos no LHCb, pois apresentam detectores frontais devido ao objetivo de seu estudo, os quarks b).

O LHC colide prótons (ou íons pesados como o chumbo) a cada 25 nanossegundos, atualmente, em média 60 colisões a cada interação entre os feixes. Para os feixes serem colimados, é necessário a aplicação de campos magnéticos intensos para atuar nas partículas do feixe, que são produzidos por magnetos supercondutores resfriados a -271,3°C por meio de hélio líquido (European [...], 2023e). A primeira aquisição de dados, *Run I*, teve a energia do centro de massa de 7,0 TeV e 8,0 TeV, na *Run II* com 13 TeV e na *Run III*, iniciada em 2022, com 13,6 TeV (European [...], 2023f).

Além da energia do feixe, outra característica de um acelerador de partículas é sua luminosidade ( $\mathscr{L}$ ) definida pela razão da intensidade do feixe ( $l_{feixe}$ ) por sua área (A) conforme a equação 6.

$$\mathscr{L} = \frac{l_{feixe}}{A} \tag{6}$$

Considerando um acelerador circular, a luminosidade é definida pela equação



**CERN** Accelerator Complex

Legenda: Complexo de aceleradores e seus detectores. Fonte: European [...], 2022.

$$\mathscr{L} = \frac{N_1 N_2 f_r n_b}{4\pi\sigma_x \sigma_y} S_\phi \tag{7}$$

onde  $N_1$  e  $N_2$  representam o número de partículas em cada pacote (*bunch*) do feixe,  $f_r$  é a freqência de revolução,  $n_b$  é o número de pacotes em cada feixe que percorrem o anel do acelerador,  $\sigma_x \in \sigma_y$  são as larguras horizontais e verticais dos feixes e  $S_{\phi}$  é o fator de perda geométrica que leva em consideração o ângulo de cruzamento entre os feixes no ponto de interação diferente de zero. O valor da luminosidade integrada na Run 3 em 2022 foi de 38,5  $fb^{-1}$  (Chiedde, 2023).

Outro parâmetro importante de um acelerador de partículas é o empilhamento de sinal (*pileup*). O empilhamento ocorre devido a múltiplas colisões próton-próton (ou Pb-Pb) quando os pacotes de partículas do feixes se cruzam no LHC. O empilhamento é proporcional à luminosidade e está definido na equação 8.

$$\mu = \frac{\mathscr{L}\sigma_i}{f_r n_b} \tag{8}$$

onde  $\sigma_i$  representa a seção de choque inelástica total de uma colisão próton-próton. Nos dados coletados pelo ATLAS, o valor médio do empilhamento  $\langle \mu \rangle$  para a Run 3 em 2022 foi de 42,5 (Chiedde, 2023). A figura 7 mostra a distribuição média de empilhamento para diferentes tomada de dados.



Figura 7 - Distribuição média de empilhamento <  $\mu$  > em diferentes tomada de dados

Legenda: Run 1 em laranja, Run 2 em verde e Run 3 em roxo. Fonte: Chiedde, 2023, p. 45.

#### 2.2 Os experimentos do LHC

O LHC apresenta quatro experimentos de grande porte em torno do anel do LHC. São eles (Chiedde, 2023):

- ATLAS (A Toroidal LHC ApparatuS): um detector de partículas projetado para estudar uma ampla gama de fenômenos físicos, incluindo o bóson de Higgs, colisões de íons pesados, candidatos a matéria escura e supersimetria. É capaz de detectar elétrons, múons, fótons e jatos de partículas, bem como partículas mais exóticas, quarks top e bósons W e Z. Mais detalhes serão apresentados na seção 2.3;
- CMS (*Compact Muon Solenoid*): é um detector de propósito geral, semelhante ao ATLAS, ou seja, também estuda tópicos de física nas energias do centro de massa do

LHC, entre eles o bóson de Higgs, supersimetria, procura por candidatos de matéria escura, tetra e penta quarks. Também esduda colisões de íons pesados, tal qual o ATLAS;

- LHCb (*Large Hadron Collider beauty*): um detector especializado no estudo de quarks b, também conhecidos como quarks *beauty*. O LHCb é usado para medir as propriedades desses quarks e estudar as interações nas quais eles estão envolvidos, particularmente violações de CP (carga-paridade) na matéria, bem como a procura por partículas formadas por tetra ou penta quarks;
- ALICE (A Large Ion Collider Experiment): um experimento desenvolvido para estudar a física do plasma de quarks e glúons, que é a forma de matéria que se acredita ter existido nos primeiros momentos após o Big Bang (Novello, 2010).
   ALICE é usado para estudar colisões de íons pesados no LHC, colisões Pb-Pb, e as partículas produzidas nessas colisões.

#### 2.3 O experimento ATLAS

O experimento ATLAS (*A Toroidal LHC ApparatuS*) é o maior detector do LHC. Conforme mostra a figura 8, o experimento ATLAS apresenta formato cilíndrico, sendo dividido nas regiões do barril (central) e das tampas (frontal). Na região central, os detectores são cilíndricos e concêntricos, de tamanho e raios diferentes e na região frontal, as tampas complementam os detectores do barril.

#### 2.3.1 Sistema de coordenadas do ATLAS

O sistema de coordenadas é dividido nos eixos cartesianos (x,y,z) como mostra a figura 9 onde a coordenada z é definida pela direção do feixe, a coordenada x aponta para o centro do LHC e a coordenada y aponta para cima e o plano transverso é o plano XY. O ângulo azimutal  $\phi[-\pi,\pi]$  é o ângulo no plano XY, em relação ao eixo X. O ângulo polar  $\theta[0,\pi]$  é o ângulo entre a direção da partícula produzida na interação pp (Pb-Pb, p-Pb) e o eixo Z.

O momento das partículas em seus respectivos eixos, está definido na equação

9:

$$p_x = p_T \cos\phi, \qquad p_y = p_T \sin\phi, \qquad p_z = p_T \sinh\phi, \qquad (9)$$



Legenda: Esquema dos detectores do ATLAS. Fonte: ATLAS, 2018.

Figura 9 - Coordenadas do experimento ATLAS



Legenda: Ângulo polar, ângulo azimutal, ponto de interação e linha do feixe do LHC. Fonte: Perez, 2018, p. 23.

em que  $p_T$  é o momento transverso definido na equação 10:

$$p_T = psin\theta. \tag{10}$$

A energia transversa depende do momento transverso e está definida na equação 11
$$E_T = \sqrt{(p_T)^2 + (mc)^2},\tag{11}$$

onde m é a massa da partícula.

A rapidez (y) é definida pela equação 12:

$$y = \frac{1}{2} \ln(\frac{E + p_T}{E - p_T})$$
(12)

A pseudorapidez(ATLAS Collaboration, 2024a),  $\eta$ , no limite de altas energias onde há partículas com velocidades ultra-relativísticas, é numericamente igual a rapidez, definida na equação 13:

$$y \approx \eta = -\ln\left[\tan\left(\frac{\theta}{2}\right)\right],$$
(13)

onde  $\theta$  é o ângulo polar. Essa quantidade é utilizada ao invés do ângulo  $\theta$ . Normalmente, os detectores são segmentados em regiões (intervalos) de  $\eta$  nas análises.

Uma variável importante para medir a distância entre as partículas é o  $\Delta R$ , definido na equação 14:

$$\Delta R = \sqrt{(\Delta \eta)^2 + (\Delta \phi)^2},\tag{14}$$

onde  $\Delta \eta = \eta_1 - \eta_2$  e  $\Delta \phi = \phi_1 - \phi_2$ , os índices são referentes a cada uma das duas partículas.

#### 2.3.2 Detector de traços ou detector interno

O detector mais interno do ATLAS é o *Inner Detector* (ID), detector de traços, dividido em *Pixel Detector* formado por pixels de Sílicio, *Semicondutor Tracker* (SCT) formado por microfitas de Sílicio (Ahmad *et al.*, 2007) e *Transition Radiation Tracker* (TRT) (ATLAS TRT Collaboration *et al.*, 2008) formado por fibras de Carbono e com tubos de gás argônio (antes era gás xenônio, porém devido ao alto custo, optou-se pelo gás argônio) (Assis, 2021; Pinto, 2022; ATLAS Collaboration, 1997).

Um campo magnético axial de 2 T é gerado por um fino ímã solenóide supercondutor que envolve o detector interno, desviando as trajetórias das partículas carregadas dentro do sistema. Ao detectar interações de partículas com o material, ele reconstrói trajetórias de partículas e determina suas cargas e momentos (Chiedde, 2023). A figura 10 apresenta o detector interno do ATLAS, ele tem a forma de cilindros concêntricos em torno do eixo de colisão.

Figura 10 - Detector interno do ATLAS



Legenda: Detector interno do ATLAS, detector semicondutor no barril, detector de pixels, detector de radiação de transição no barril, detector de transição na tampa, detector semicondutor na tampa.

Fonte: European [...], 2008b.

#### 2.3.2.1 Pixel Detector

O *Pixel Detector* tem múltiplas funções, incluindo rastrear as partículas com alta resolução, reconhecimento de padrões que atende aos requisitos de vértice, reconstrução de pontos de interação e vértices secundários. Ele fornece medições precisas na região mais próxima do local de interação (Chiedde, 2023).

As partículas carregadas vindas da colisão do feixe interagem por ionização com os pixels e as tiras de silício. A reação gerada pela partícula ao passar pelas tiras permite a leitura dos dados do traço nesta região (Gaspar, 2016).

## 2.3.2.2 Semicondutor Tracker (SCT)

O Semicondutor Tracker usa sensores de microfita e é dividido em um cilindro e uma parte final da tampa. O cilindro é composto por quatro camadas concêntricas e as tampas consistem em nove discos, proporcionando cobertura de até  $|\eta| < 2, 5$ . O SCT utiliza módulos individuais compostos por sensores de microfita de silício de dupla face. O SCT fornece uma média de quatro medições por traço, tornando-o uma importante ferramenta para detecção precisa e boa reconstrução da trajetória das partículas carregadas (Chiedde, 2023).

## 2.3.2.3 Transition Radiation Tracker (TRT)

O Transition Radiation Tracker contém 50.000 longos tubos de derivação de poliamida, cada um dividido em duas partes, no centro, preenchido por gás e na tampa, apresenta 320000 tubos adicionais que possibilitam uma média de 36 medições por traço, melhorando significativamente a resolução do momento. Os espaços entre os tubos são preenchidos por um material que emite radiação de transição quando partículas carregadas passam por ele, permitindo a identificação de várias dessas partículas. Ao passarem pelos tubos, as partículas ionizam o gás dentro do tubo, resultando em uma corrente fluindo ao longo dos fios e levando à detecção (Chiedde, 2023).

O TRT aumenta a capacidade da identificação dos elétrons porque estes tem alta probabilidade de emitir fótons de radiação de transição quando atravessam as fibras de carbono que formam o detector. Tais fótons têm comprimento de onda característico, arrancando elétrons da camada K (primeira camada eletrônica) do gás e aumentando o valor da corrente medida no detector (Assis, 2021).

## 2.3.3 Sistema de Calorimetria

Os calorímetros tem por função medir a energia das partículas que interagem com seus materiais, aquecendo o meio ou excitando-o. Há dois tipos de calorímetros, o de amostragem e os homogêneos. O calorímetro de amostragem é dividido em meio passivo, em que há a interação com a partícula, absorvendo sua energia e meio ativo onde é gerado o sinal. O calorímetro homogêneo apresenta apenas um material que realiza as duas funções, apresentando uma resolução melhor de energia, já que há perdas consideráveis no meio passivo dos calorímetros de amostragem e eles são mais caros (Pinto, 2022).

Os calorímetros apresentam uma série de vantagens nos experimentos de altas energias, são elas (Peralva, 2015):

- calorímetros podem ser sensíveis tanto a partículas neutras quanto a carregadas;
- a identificação de partículas pode ser feita com alta eficiência devido às diferenças na forma de deposição de energia;
- para conter o desenvolvimento de cascatas dos objetos a serem medidos, a profundidade dos calorímetros aumenta logaritmicamente com a energia, o que permite o projeto de detectores mais compactos;
- calorímetros podem ser segmentados, o que permite tanto medida da energia quanto de trajetória das partículas;
- uma resposta rápida (menor que 50 ns) pode ser atingida com os calorímetros, o que é importante num ambiente com alta taxa de eventos;
- a informação de energia obtida dos calorímetros pode ser usada para filtrar eventos de interesse com alta seletividade.

O ATLAS, posiciona seu sistema de calorímetria a 1,5 metros do ponto de colisão, ele é divido em dois calorímetros principais: eletromagnético e hadrônico, e ainda há um pré-amostrador (*pre-sample*) (Peralva, 2015). A figura 11 mostra as divisões dos calorímetros eletromagnético e hadrônico.

A interação das partículas com os materiais dos calorímetros produzem uma cadeia de interações (ou ramificações) em que seu conjunto é chamado de chuveiro e dependendo das interações, esses chuveiros são classificados em chuveiros eletromagnéticos ou hadrônicos. As partículas como elétrons, fótons e pósitrons produzem um chuveiro eletromagnético no calorímetro eletromagnético enquanto as partículas formadas por quarks (hádrons) produzem um chuveiro hadrônico no seu respectivo calorímetro. A figura 12 apresenta os detectores do ATLAS com as interações de cada uma das partículas e a formação de chuveiros nos respectivos calorímetros (Assis, 2021).

## 2.3.3.1 Pré-amostrador (PS)

O calorímetro pré-amostrador é formado por uma fina camada de argônio líquido (*Liquid Argon*, LAr) (ATLAS Collaboration, 1996) e eletrodos, sua função é absorver a energia das partículas oriundas de chuveiros formados antes do sistema de calorimetria, ou seja, no detector de traços e no criostato. Dessa forma, o pré-amostrador possibilita a calibração de energia perdida pelas partículas que interagem com seu material. Sua região de cobertura estende-se até  $|\eta| < 1, 8$  (Pinto, 2022).



Figura 11 - Calorímetro eletromagnético e hadrônico do ATLAS

Legenda: Calorímetro eletromagnético e hadrônico do ATLAS, calorímetro de telhas do barril, calorímetro de telhas na extensão do barril, calorímetro eletromagnético frontal - LAr (FCal), calorímetro eletromagnético no barril - LAr, calorímetro eletromagnético nas tampas - LAr (EMEC), calorímetro hadrônico nas tampas - LAr (HEC). LAr indica que o calorímetro usa argônio líquido (*Liquid Argon*) como meio ativo.

Fonte: European [...], 2008a.

#### 2.3.3.2 Calorímetro Eletromagnético (ECAL)

O Calorímetro Eletromagnético utiliza LAr como meio ativo com absorvedores de eletrodos de cobre e o meio passivo de placas de chumbo. O sinal eletrônico é gerado pela absorção das partículas geradas pelo chuveiro realizando ionização do LAr. Ele foi construído para operar na faixa de energia de 50 MeV até 3 TeV (Araújo, 2019).

O ECAL apresenta formato de acordeão e é dividido em três camadas. A figura 13 apresenta o formato do ECAL. A primeira camada (EM1) é composta por tiras finas com grande granularidade em  $\eta$ , responsável por realizar uma boa leitura da posição, além de ser importante pela detecção de fótons por eles não serem medidos no detector de traços. A segunda camada (EM2) composta por torres quadradas, tem a função de absorver a maior quantidade de energia e relaciona o perfil lateral do chuveiro com a contribuição do ruído por empilhamento para a medição de energia. A terceira camada (EM3) apresenta menos granularidade em  $\eta$  devido a redução do número de canais eletrônicos, mas permite a separação de chuveiros de altas energias e contribui para separação de fóton/jato e elétron/jato (Freund, 2018).



Figura 12 - Interação das partículas com todos os detectores do ATLAS

Legenda: De cima para baixo: espectrômetro de múons, calorímetro hadrônico, calorímetro eletromagnético, detector interno e centro de colisão.

Fonte: Gaspar, 2016, p. 14.

Esse calorímetro possui três regiões de fissura (*crack*) onde há degradação da resposta do detector. Elas são localizadas em  $|\eta| < 0,02$ ;  $1,37 < |\eta| < 1,54$  e  $2,47 < |\eta| < 2,5$  devido ao material morto, sem detectores (Araújo, 2019).

#### 2.3.3.3 Calorímetro Hadrônico (HCAL)

O Calorímetro Hadrônico apresenta um conjunto de calorímetros com tecnologias distintas, são eles: Calorímetro Hadrônico de Telhas (TileCal), Tampas do HCAL (HEC) e Calorímetro dianteiro (FCAL, *Forward Calorimeter*).

## 2.3.3.4 Calorímetro Hadrônico de Telhas (TileCal)

O TileCal apresenta como meio ativo telhas de cintiladores de plástico e meio passivo, placas de aço. Os cintiladores são excitados pelas partículas carregadas do chuveiro gerando fótons que são capturados pelas fibras óticas sendo seus sinais amplificados por Fotomultiplicadoras (PMT) (Balabram Filho, 2014). A figura 14 apresenta os detalhes de um módulo do TileCal, onde se vê a posição das PMTs (Woerden; Wilkens; Santoni, 2015). O pulso de saída da PMT passa por um circuito de conformação (*shaper*)

#### Figura 13 - Barril do ECAL (acordeão)



Legenda: Eletrodos, absorvedores, camada interna/externa de cobre, aço inoxcidável, cola, chumbo e intervalo preenchido com argônio líquido. Fonte: Freund, 2018, p. 75.

que fornece um pulso com amplitude proporcional à energia depositada. Pela estimação da amplitude do pulso, determina-se a energia depositada pela partícula em um dado canal. Como há vários canais, há a seleção de canais com informação relevante onde só eles são utilizados para a reconstrução de energia. O pulso conformado é amplificado por dois amplificadores para que toda a faixa de energia de 220 MeV a 1,3 TeV seja coberta. Por último, os sinais analógicos são convertidos em digitais por um conversor Analógico-Digital (ADC) com uma janela de 7 amostras (150 ns) para cobrir todo o pulso, então as amostras são enviadas para *Read Out Drivers* (RODs) com sua energia estimada para os eventos aceitos pelo primeiro nível de *trigger*, L1, referente à calorimetria (Peralva, 2015).

O TileCal é composto pelo barril central, barril estendido e calorímetro intermediário que tem como função recuperar parte da informação perdida (Freund, 2018). A figura 15 apresenta a divisão do TileCal em  $\eta$ . O objetivo do TileCal é fazer medidas precisas da energia de hádrons, jatos e taus e sua região de cobertura é em  $\eta < 1,7$  (Peralva, 2015).





Legenda: Segmentação do TileCal, com as placas de aço alternada com os cintiladores e a posição das PMTs.

Fonte: Woerden; Wilkens; Santoni, 2015, p. 2.

### 2.3.3.5 Tampas do HCAL (HEC) e Forward Calorimeter (FCAL)

O HEC apresenta como meio ativo, o LAr e seu meio passivo é cobre em formato de tampa. Sua composição foi desenvolvida para ter uma maior resistência à radiação e melhor custo-benefício (Freund, 2018).

O Forward Calorimeter, assim como o HEC, precisa ter materiais que suportem elevado índice de radiação, pois está próximo do tubo do feixe, por isso, ele apresenta como meio passivo uma placa de cobre com furos igualmente espaçados onde são introduzidos hastes de cobre e o meio ativo é LAr. O FCAL apresenta três camadas com argônio líquido, a primeira camada é formada por cobre, ela é projetada para medir chuveiros eletromagnéticos, as outras duas camadas usam tungstênio para chuveiros hadrônicos. Assim, o FCAL pode medir os dois tipos de chuveiros, eletromagnéticos e hâdrônicos. Ele está situado na região  $3, 1 < |\eta| < 4, 9$  e sua principal função é reconstruir a energia de jatos e realizar uma melhor medição da perda de momento transverso (Chiedde, 2023).

# Figura 15 - Segmentação em profundidade e em $\eta$ das células do barril central e barril estendido do TileCal



Legenda: Segmentação em profundidade e em  $\eta$ das células do barril central, barril estendido e calorímetro intermediário do TileCal.

Fonte: ATLAS Collaboration, 2018, p. 2. Adaptado pelo autor.

## 2.3.4 Sistema de Múons

O Sistema de Múons ou a Câmara de Múons ou o Espectrômetro de Múons é o detector mais externo do ATLAS, ele é preenchido por gás com um fio longitudinal no centro. Os múons são as únicas partículas com carga que atravessam todos os detectores do ATLAS, pois essas partículas depositam apenas uma fração de sua energia nos calorímetros, interagindo fracamente com a matéria e apresentam uma vida média alta (Assis, 2021).

A câmara de múons é formada por camadas de placas resistivas (RPC, *Resistive Plate Chambers*) que são utilizadas em conjunto com informações de outros detectores, *Thin-gap chambers* (TGC) e de tiras de cátodo (CSC, *Cathode Strip Chambers*) que contribuem para a taxa de amostragem na região de tampa, além de tubos de deriva monitorados (MDT, *Monitored Drift Tube*) que são utilizados para medição da trajetória dos múons (Moura Junior, 2014). A figura 16 apresenta a Câmara de Múons. Há um segundo sistema magnético chamado de magneto toroidal que curva a trajetória dos múons para uma melhor determinação do seu momento (Assis, 2021).

2.3.4.1 Tubos de deriva monitorados (MDT) e camada de tiras de catodo (CSC)

As câmaras MDT estão dispostas em três camadas entre e sobre as bobinas do toróide supercondutor, que gera o campo magnético toroidal e cobrem a região  $|\eta| < 2, 7$ . Essas câmaras são responsáveis pela medição da posição em  $\eta$ . As câmaras CSC estão



Figura 16 - Espectrômetro de múons do ATLAS

Legenda: Espectrômetro de múons do ATLAS, *Thin-gap chambers* (TGC), camada de tiras de cátodo (CSC), toróide no barril, camadas de placas resistivas (RPC), toróide na tampa e tubos de deriva monitorados (MDT).

Fonte: European [...], 2008c.

localizadas na camada mais interna cobrindo a faixa  $2, 0 < |\eta| < 2, 7$  e fornecem quatro medições independentes nas direções  $\eta \in \phi$  (Chiedde, 2023).

2.3.4.2 Camadas de placas resistivas (RPC) e Thin-gap chambers (TGC)

O ATLAS usa dois sistemas de disparo para detectar múons. Este sistema consiste em câmaras especiais de múons que podem enviar sinais rapidamente após a passagem de uma partícula, permitindo a identificação da interação na qual foi produzida. Essas câmaras medem as coordenadas de flexão e não-flexão dos traços, fornecendo informações adicionais sobre os traços de múons. As camadas de placas resistivas (RPC) estão instaladas na região do barril. A *Thin-gap chambers* (TGC) estão instaladas na região da tampa e fornecem informações mais precisas. Juntos, os dois sistemas de disparo cobrem a faixa  $|\eta| < 2, 4$ , com o RPC operando em  $|\eta| < 1,05$  e o TGC cobrindo o restante da faixa. Os dados combinados de ambos ajudam os pesquisadores a estudar as características dos múons com mais detalhes (Chiedde, 2023).

## 2.3.5 Sistema de aquisição de dados e sistema de filtragem (Trigger)

A taxa de interação de colisões no ATLAS é de aproximadamente  $10^9$  eventos por segundo, ou seja, cerca de 70 TB por segundo chegam ao sistema de aquisição de dados que não tem capacidade para armazenar essa grande quantidade de dados, por isso há o sistema de filtragem que deve diminuir essa quantidade de dados para armazenamento. A filtragem é realizada com o sistema TDAQ de Aquisição de dados e *Trigger (Trigger and Data Acquisition)* que tem como objetivo selecionar os eventos de interesse, reduzindo a taxa de eventos (Assis, 2021).

O TDAQ é dividido em dois níveis, o L1 e o HLT (*High Level Trigger*). O L1, em nível de *hardware*, recebe informação do Primeiro Nível de Filtragem para o Sistema de Calorimetria (L1Calo) e do Primeiro Nível de Filtragem para o Espectrômetro de Múons (L1Muon) (Xavier, 2012). Se o evento é aceito pelo L1, ele é armazenado no Sistema de Leitura (ROS) como uma Região de Interesse (RoI) e processado pelo HLT. O HLT utiliza toda a granularidade do detector e as informações do detector interno atuando nas Regiões de Interesse que foram identificadas no primeiro nível (L1) (Assis, 2021; Freund, 2018). A figura 17 apresenta o modelo do sistema de *Trigger* do ATLAS.

Figura 17 - Sistema de Trigger do ATLAS



Legenda: O Sistema de *Trigger* do ATLAS é dividido em duas partes, a primeira é o L1 em *hardware* e a segunda é o HLT (*High Level Trigger*) em *software*. Fonte: Freund, 2018, p. 79.

O sistema de filtragem do ATLAS contém os seguintes elementos (Torres, 2010; Pinto, 2022):

- Elemento de *trigger*: ativado por um algoritmo que sinaliza a validação de um critério de seleção (corte), por exemplo, no L1, uma RoI, no HLT, é gerado através de sequências de algoritmos de extração de características e teste de hipóteses;
- L1Item: configurações de cortes em sequências aplicados em *hardware* em uma determinada RoI gerada pelo L1 em que a aprovação da RoI iniciará um conjunto de assinaturas;
- Assinatura ou cadeia: combinação de elementos de *trigger* e sequências de algoritmos que pode levar a uma decisão positiva do sistema de filtragem. Por exemplo, uma assinatura e26 representa um elétron com energia transversa superior a 26 GeV;
- *Slice*: é um conjunto de assinaturas utilizadas para um tipo de partícula como elétron, múon ou fóton;
- *Menu*: é um conjunto de *slices* compreendendo todas as assinaturas durante uma tomada de dados. Dentro de um *slice*, se uma ou mais assinaturas são satisfeitas, o evento é aprovado com todos os sinais do detector sendo armazenados.

As cadeias de grande importância são as cadeias primárias que contém as medições precisas das propriedades das partículas do MP de Física de Partículas, além da busca por nova Física, como o Z' (Pinto, 2022).

As assinaturas do ATLAS são nomeadas com sufixos e combinações dos mesmos para definir cortes e estratégias de filtragem quando há a montagem da cadeia (*chain*) no sistema de *trigger*, são elas (Pinto, 2022):

- $e(E_{Tcut})$  (ou  $g(E_{Tcut})$ ): Assinatura de elétrons, e, (ou fótons, g) com corte de energia dado pelo valor de  $E_{Tcut}$ . A partir dessa nomenclatura, há aplicação de um corte de  $E_T - 3$  GeV em  $E_T$  na etapa de pré-seleção rápida e  $E_T$  na etapa de seleção precisa do sistema de filtragem;
- etcut: corte único em energia é aplicado na cadeia;
- very loose, loose, medium e tight: são pontos de operação de todos os testes de hipótese utilizados na cadeia. No critério loose, há uma maior probabilidade de detecção com uma maior taxa de eventos de não interesse (falso alarme), enquanto no critério tight é o oposto, conseguindo uma amostra mais pura com cortes mais rígidos e o critério medium é um critério intermediário entre os dois, já o critério very loose apresenta as características do critério loose com uma maior intesidade;

- *lhveryloose*, *lhloose*, *lhmedium* e *lhtight*: apresentam a utilização da estratégia de máxima verossimilhança (*Likelihood* (Alison *et al.*, 2013)) nos respectivos pontos de operação;
- nod0: indica que o parâmetro de impacto transverso com respeito ao vertíce primário, d0, não é utilizada no cálculo da máxima verossimilhança;
- *iloose* ou *ivarloose*: indica a exigência de candidatos isolados.

Para exemplificar, há a seguinte configuração: e60\_lhmedium\_nod0 que significa que é um elétron com mais de 60 GeV (57 GeV) utilizando a estratégia da máxima verossimilhança sem d0 no ponto de operação *medium*.

2.3.5.1 Primeiro nível do sistema de filtragem (L1)

O L1 é feito em *hardware*, utiliza a informação proveniente dos calorímetros e dos detectores rápidos de múons, pois os algoritmos dos detectores de traços apresentam alto custo computacional e nesse nível, a decisão é tomada na ordem de microssegundos (Achenbach *et al.*, 2008). O L1 é dividido em L1Calo, referente ao sistema de calorimetria, L1Muon referente ao sistema relacionado aos detectores rápidos de múons e o processador central de *trigger* (CTP) que é alimentado pelos sistemas anteriores (ATLAS Collaboration, 2012a; ATLAS Collaboration, 2012b). No L1Calo, as células dos dois calorímetros são agrupadas em 6 células devido à necessidade dos requisitos de latência. Cada conjunto de células produz um único sinal que é comparado com um limiar de corte de energia pré-definido (Pinto, 2022).

A detecção de elétrons é realizada com cortes simples de informações obtidas pela leitura das células do calorímetro como energia transversa, perfil lateral e longitudinal do chuveiro (Pinto, 2022). A figura 18 apresenta o esquema de torres do algoritmo do L1.

O algoritmo do L1 baseia-se na divisão de 4 x 4 torres de *trigger* sendo uma janela em  $\eta \ge \phi$ . Essa janela percorre o calorímetro até  $|\eta| < 2, 5$  em passos de uma torre em  $\eta$  e em  $\phi$ . A seleção do L1 para um possível candidato ocorre quando os critérios a seguir são aprovados:

- soma das torres em uma região 2 x 2 torres em  $\eta \ge \phi$  localizadas no centro da janela deve ser maior que um determinado valor de corte;
- determinação da  $E_T$  da região analisada do L1: quatro *clusters* (grupo de células que definem a região de interação da partícula com o calorímetro) eletromagnéticos sobrepostos que correspondem à soma de duas torres sendo que o *cluster* mais energético deve possuir um valor em  $E_T$  maior ou igual a um determinado valor.



Figura 18 - Esquemas de torres do algoritmo L1

Legenda: Torres do *Trigger*, calorímetro eletromagnético (amarelo) e hadrônico (rosa). Região de intresse (verde). Fonte: Pinto, 2022, p. 54.

O primeiro critério serve para determinar uma possível Região de Interesse (RoI). Em casos de cortes sem isolamento, o segundo critério deve ser aceito para a região ser aprovada. Já os cortes com isolamento, há mais 3 critérios que precisam ser aprovados:

- HAD<sub>Core</sub> (Núcleo hadrônico): soma das quatro torres do calorímetro hadrônico (posicionadas na mesma direção dos *clusters* eletromagnéticos) seja menor ou igual a um patamar;
- $EM_{Isol}$ : Anel de isolamento eletromagnético, soma da energia transversa das 12 torres eletromagnéticas ao redor dos quatro *clusters* eletromagnéticos deve ser menor ou igual ao patamar de decisão estabelecido;
- HAD<sub>Isol</sub>: Anel de isolamento hadrônico, soma da energia transversa das 12 torres hadrônicas ao redor do núcleo hadrônico deve ser menor ou igual ao patamar de decisão estabelecido.

Se todos os critérios acima forem aprovados, será identificada a Região de Interesse (RoI) e enviada para o sistema de filtragem de alto nível (HLT) (Ruiz-Martinez, 2016).

#### 2.3.5.2 Sistema de filtragem de alto nível (HLT)

O HLT para elétrons, apresenta uma maior latência, possibilitando a utilização de nós computacionais interligados para processar a informação oriunda das Regiões de Interesse. O HLT de elétrons é subdividido em duas etapas, a etapa rápida e a etapa precisa em que ambas apresentam mais duas subdivisões. A etapa rápida tem a função de reduzir a quantidade de eventos de não interesse no início da cadeia e a etapa precisa tem a função de calibrar a energia das células e reconstruir a informação do traço e da calorimetria (Pinto, 2022). A figura 19 apresenta as etapas do *Trigger* HLT e suas subdivisões.





Legenda: Etapa rápida (*Fast*) em cinza e etapa precisa (*Precision*) em vermelho do HLT. Fonte: Pinto, 2022, p. 57.

Na etapa rápida, emprega-se algoritmos com objetivo de refinar a posição em  $\eta \ge \phi$  da RoI utilizando as células da segunda camada do calorímetro eletromagnético em sua granularidade mais fina. Na sequência, inicia-se o processo de reconstrução de um conjunto de grandezas físicas baseadas na informação da calorimetria (Pinto, 2022). Essas grandezas físicas são (ATLAS Collaboration, 2016a; Mistry; Thompson; Williams, 2016):

- *E<sub>ratio</sub>*, apresenta a razão entre o primeiro máximo de energia da camada EM1 menos o segundo máximo da mesma camada sobre a soma de ambos;
- $R_{\eta}$  é a razão de energia das células 3 x 7 para as células 7 x 7 centralizadas no depósito de energia do elétron na camada EM2;
- $f_1$  é a fração de energia entre a energia total depositada na camada EM1 sobre a energia total medida no calorímetro eletromagnético para o chuveiro EM que está sendo avaliado (identificado);
- $f_3$  é a fração de energia entre a energia total depositada na camada EM3 sobre a energia total medida no calorímetro eletromagnético para o chuveiro EM que está sendo avaliado (identificado);
- $w_{\eta^2}$  é a largura lateral do chuveiro na camada EM2;
- $w_{stot}$  é a largura do chuveiro na camada EM1;
- $E_{T,EM}$  (Energia Transversa Eletromagnética): soma da energia transversa depositada nas três camadas eletromagnéticas (EM1, EM2 e EM3), em uma região de 3 x 7 células em  $\eta \ge \phi$  centrada na célula mais energética (*hot cell*) da segunda camada eletromagnética;
- $E_{T,had1}/E_{T,EM}$ : razão de energia transversa hadrónica da primeira camada (HAD1) pela energia transversa eletromagnética;
- Anéis de energia (*Rings*): algoritmo que realiza a geração de anéis concêntricos a partir da *hot cell* que somam o módulo da energia depositada em cada camada do calorímetro.

As seis primeiras variáveis físicas e os anéis serão melhores descritos nos capítulos 5 e 4, respectivamente.

Na etapa precisa, há a calibração da energia das células utilizando uma técnica multivariável para melhorar a aproximação de energia pela eletrônica do detector em relação à energia real da interação do chuveiro. Em sequência, calcula-se a  $E_{T,EM}$  e aplica-se um corte já configurado pela cadeia. Por último, a reconstrução precisa é realizada com o casamento de  $\eta$  e  $\phi$  entre a posição extrapolada do candidato a traço até a segunda camada eletromagnética e a posição do cluster dada por ela, na sequência são calculadas

todas as grandezas físicas de calorimetria e de traço. Se for aprovado o candidato a elétron, toda a informação do evento será armazenada para uma análise *offline* posterior (Pinto, 2022).

## 2.4 Reconstrução dos objetos físicos pelo ATLAS

As partículas produzidas nas colisões próton-próton atravessam os detectores do ATLAS, a interação das partículas com o material dos detectores é registrada através de sinais eletrônicos que são digitalizados e gravados nos computadores do experimento, após passarem pelo sistema de *Trigger*. Posteriormente, os eventos são reconstruídos através de software que une os pontos nas camadas do ID (considerando que o movimento das partículas é radial) obtendo assim a trajetória das partículas carregadas. Nos calorímetros, há a reconstrução dos chuveiros gerados, o que permite a medida da energia das partículas, bem como suas posições no detector. Os sinais deixados no espectrômetro de múons são unidos ao prolongamento dos traços reconstruídos no ID o que permite medir o momento do múon e fazer sua identificação (Assis, 2021).

Os fótons são reconstruídos pela deposição de energia devido ao chuveiro no calorímetro eletromagnético, verificando que não existe nenhum traço (trajetória) reconstruído no ID apontando para os fótons, pois os fótons não deixam traço no ID por não apresentarem carga elétrica (Assis, 2021).

Os jatos são reconstruídos por algoritmos de clusterização com parâmetro de raio R específico. Esses algoritmos usam topoclusters que são aglomerados topológicos (ATLAS Collaboration, 2017a; ATLAS Collaboration, 2017b) construídos a partir das células do calorímetro com sinal acima do ruído para calcular toda a energia depositada pelas partículas (Assis, 2021).

#### 2.4.1 Reconstrução dos elétrons

Por ser uma partícula de interesse para esse trabalho e por ser ótimo candidato para exploração de Física, assim como para nova Física, essa seção será dedicada à reconstrução *offline* do elétron. Sua reconstrução segue os seguintes passos: reconstrução do *cluster* por sementes, reconstrução de traços, ajuste fino de traços para candidato a elétron e reconstrução final dos candidatos (ATLAS Collaboration, 2016b).

Considerando que a região do detector é  $|\eta| < 2, 5$ , a reconstrução do *cluster* da construção de torres é realizada com a granularidade da EM2, através da soma de energia das células das camadas longitudinais do ECAL provenientes da região. Uma janela de 5 x 5 torres procura uma região com  $E_T > 2, 5$  GeV e que seja um máximo local. Uma

vez encontrada, gera-se uma semente cuja posição é calculada pela ponderação de energia das células dentro de uma janela 3 x 3 concêntrica à janela anterior. Para não armazenar várias sementes, é escolhida apenas a semente mais energética. Por último, dependendo da partícula e sua incidência, os *clusters* são reconstruídos, com o processo sendo iniciado na EM2 a partir da posição da semente com o baricentro de energia calculado e propagado para EM1 e EM3 (o PS utiliza o baricentro da EM1), onde são gerados os *clusters* para essas camadas (Pinto, 2022).

O traço é reconstruído em duas etapas: reconhecimento de padrões e ajuste do traço. Devido à perda de energia do elétron por bremstrahlung no ID, o reconhecimento de padrões utiliza um algoritmo próprio que permite recuperar até 30% da parcela de energia perdida. Isso auxilia na estratégia padrão de reconstrução de traços que assume como hipótese que a partícula é um píon. Inicia-se o algoritmo com sementes de traço de  $P_T > 1$  GeV empregando a hipótese de píons, caso ela falhe, repete-se a reconstrução do traço para hipótese de elétrons. Por último, na reconstrução final, ocorre a união de informação através do critério loose por extrapolação do traço até seu ponto de impacto com a EM2 e da posição do baricentro de energia calculado dessa camada. Se tiverem muitos traços apontando para o mesmo cluster, a escolha do traço primário é realizada por um algoritmo que leva em consideração o  $\Delta R$ , diferentes hipóteses de momentos, o número de pontos no Detector de Pixel e a exigência de pelo menos um ponto no SCT (semiconductor tracker) (Pinto, 2022).

Para saber se um elétron é isolado (como em decaimentos de  $W \to e\nu$  ou  $Z \to ee$ ) ou não, tendo uma melhor eficiência na seleção de elétrons de interesse, utiliza-se a aplicação de cortes lineares em variáveis de isolamento advindas da energia de partículas próximas ao candidato a elétron. As duas variáveis de isolamento são: isolamento em calorimetria,  $E_T^{cone,\Delta R}$  e isolamento variável do traço,  $p_T^{varcone,\Delta R}$  em que ambas fazem a soma das energias ou momentos transversos dentro de um cone definido por  $\Delta R$  (Anastopoulos et al., 2016; Pinto, 2022).

O efeito de empilhamento de sinal deve-se ao congestionamento de sinais no detector o que afeta a reconstrução de elétrons. A interferência no desenvolvimento de sinais (empilhamento) tem maior probabilidade de sobreposição de sinais oriundos de partículas diferentes em regiões próximas. O empilhamento pode ocorrer de duas formas, *in-time*, o empilhamento vem do mesmo evento de cruzamento de pacotes do LHC, ou *out-of-time*, há o desenvolvimento do sinal eletrônico de um único cruzamento durante vários ciclos de cruzamentos de pacotes, sendo o último o que contribui mais para o efeito de empilhamento. Além disso, pode haver contaminação de jatos hadrônicos que interferem na reconstrução e até podem fazer com que o perfil do elétron torne-se o perfil de um jato, classificando-o erroneamente (Pinto, 2022).

Através do número médio de interações por cruzamento de pacote  $(\mu)$  e o número de vértices (nvtx), pode-se modelar uma probabilidade de ocorrências de empilhamento, porém o número de vértices não está disponível no *online*, portanto somente o  $\mu$  é utilizado no sistema de filtragem *online*. Na identificação de elétrons, o empilhamento se comporta linearmente, com isso, empregou-se um ajuste linear no limiar de decisão para o estimador de empilhamento (Pinto, 2022).

Como mostrado anteriormente, os detectores do ATLAS não são homogêneos em todas as regiões, ou seja, suas eficiências de detecção são diferentes em cada região, por isso, os métodos realizados nas análises físicas para identificação de partículas consideram medições em diferentes regiões do espaço de fase que é definido no plano da energia transversa versus  $\eta$  ( $E_T \ge \eta$ ) (Pinto, 2022).

## 2.4.1.1 Método Tag and Probe

O método Tag and Probe é um discriminador importante para análises em que não se sabe a natureza da amostra sem ter um viés tendencioso, além disso, ele permite retirar a eficiência diretamente do detector. Para esse trabalho, na identificação de elétrons, utilizaram-se as amostras dos decaimentos do bóson Z não radioativo ( $Z\rightarrow$ ee) pelo método Tag and Probe.

O evento deve ter pelo menos dois elétrons reconstruídos que atendam o seguinte critério: um dos candidatos (tag) seja aceito como elétron enquanto o outro candidato (probe) precisa formar, em conjunto com o tag, as propriedades conhecidas do outro elétron (Freund, 2018).

O candidato a elétron *offine tag* deve ser aprovado pelos os critérios (Pinto, 2022):

- deve possuir um objeto *cluster* e *Track* associado;
- precisa ser aceito por um dos critérios restritivos do *offline*, por exemplo, *offline lhmedium*;
- ter  $E_T > 25$  GeV;
- deve ser encontrado na região de maior precisão do detector;
- o evento deve ser aceito por pelo menos uma das cadeias primárias dedicadas à coleta de eventos contendo ao menos um elétron de menor energia sem a aplicação de pré-escala;
- em dados de simulação, precisa ser um elétron de acordo com a informação do que foi gerado pelo Monte Carlo;
- precisa ter um elemento de *trigger* associado.

O candidato a elétron *offline probe* precisa ser aprovado nos seguintes critérios (Pinto, 2022):

- deve possuir um objeto *cluster* e *Track* associado;
- não deve possuir mais de um jato com  $E_T > 20$  GeV em torno de  $\Delta R < 0, 4$ ;
- em dados de simulação, precisa ser um elétron de acordo com a simulação de Monte Carlo.

## 2.5 Atualizações da Run 3

Nesta seção, serão abordado algumas atualizações referentes ao sistema de trigger dos calorímetros da Run 3 principalmente para elétrons.

## 2.5.1 L1Calo

Para a *Run 3*, o L1Calo recebeu um aumento de granularidade com as *Super-Cells* que foram introduzidas na parte de argônio líquido do calorímetro. As *SuperCells* contém a soma de quatro ou oito células do calorímetro, cada torre de *trigger* tem 10 *SuperCells* (ATLAS Collaboration, 2024b). A figura 20 apresenta uma torre de *trigger* com 10 *SuperCells*.

Figura 20 - Torre de trigger com 10 SuperCells



Legenda: Divisão de camadas do calorímetro eletromagnético por quantidade de SuperCells.

Fonte: ATLAS Collaboration, 2024b, p. 8.

A atualização do L1Calo inclui um novo extrator de características eletromagnético (eFEX) e de jatos (jFEX), assim como um extrator global de características (gFEX). Toda a granularidade das *SuperCells* está disponível no eFEX para reconstrução eletromagnética de objetos e hadronicamente para o decaimento de léptons  $\tau$ , assim como as variáveis de *shower shapes* para identificação. Um algoritmo de subtração de *pile-up* foi introduzido no JFEX e gFEX para melhorar a eficiência, a taxa e a pureza do *trigger* para jatos e para a soma de energia (ATLAS Collaboration, 2024b). Essa atualização melhorou a eficiência, como pode ser visto na figura 21.

Figura 21 - Eficiência do trigger L1



Legenda: *Legacy* é o sistema do L1 anterior e eFEX é o sitema atual. Fonte: ATLAS Collaboration, 2024b, p. 9.

#### 2.5.2 HLT Calorimeter (HLTCalo)

No HLT *Calorimeter*, há dois diferentes algoritmos de reconstrução de energia depositada: o algoritmo de janela deslizante utilizado na etapa rápida de reconstrução de elétrons e fótons e o algoritmo *topo-cluster* que inicia com uma célula semente e soma iterativamente as células vizinhas se elas apresentarem uma energia acima de um determinado limite que é uma função da média quadrática da resposta eletrônica esperada com o empilhamento acumulado ( $\sigma$ ). O algoritmo seleciona células que apresentam uma energia maior do que  $4\sigma$ , depois maior que  $2\sigma$  e por último maior que  $0\sigma$ . Este algoritmo é um dos que mais consomem recursos da reconstrução do HLTCalo (ATLAS Collaboration, 2024b).

Para o cálculo da energia, é importante levar em consideração os efeitos de empilhamento. Para a *Run 3*, tornou-se mais eficiente a correção de *pile-up* ao se separar em uma componente de execução longa de uma componente de evento por evento. O

algoritmo de janela deslizante permite uma boa estimativa da energia dos elétrons, porém o algoritmo *topo-cluster* capta uma maior atividade em baixa energia e faz a reconstrução em uma Região de Interesse (RoI) (ATLAS Collaboration, 2024b).

# 3 APRENDIZADO DE MÁQUINA

A aprendizagem de máquina, no contexto de redes neurais, é definida por Haykin (Haykin, 2001) como:

Aprendizagem é um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre (Haykin, 2001, p. 75).

Essa aprendizagem pode ocorrer de várias formas, duas serão descritas a seguir, a aprendizagem com um professor ou sem. Na aprendizagem com um professor ou aprendizagem supervisionada, as entradas da rede apresentam rótulos (dados pelo "professor"), ou seja, quando inicia-se o treinamento da rede, o estímulo passa pela rede e no final há uma comparação entre o sinal desejado (rótulo) e o sinal real.

Na aprendizagem sem um professor, não há exemplos rotulados e ela apresenta duas subdivisões: aprendizagem por reforço que é mais utilizada em ambientes dinâmicos e aprendizagem não-supervisionada onde a rede tem a habilidade de formar representações internas codificando as características de entrada e criando novas classes (Haykin, 2001).

## 3.1 Redes Neurais

As redes neurais foram criadas com base no cerébro humano que é um computador complexo, não-linear e paralelo (Haykin, 2001). O cerébro humano aprende com base na experiência vivida em seu ambiente, já a rede neural aprende com uma interligação maciça de células computacionais simples, neurônios, que armazenam informação através de pesos sinápticos (Haykin, 2001). Uma rede neural é um processador paralelamente distribuído formado por unidades de processamento simples que armazenam conhecimento experimental através do seu processo de aprendizagem fazendo-o disponível para uso (Haykin, 2001).

O processo de aprendizagem ocorre através do algoritmo de aprendizagem que modifica os pesos sinápticos da rede de forma ordenada com base no objetivo desejado, há também a possibilidade de modificar a topologia como por exemplo a remoção de neurônios ou o crescimento de novas conexões sinápticas (Haykin, 2001).

A utilização de redes neurais apresenta diversas vantagens dentre elas se destacam: não-linearidade que facilita a resposta de um sistema que apresente o sinal de entrada não-linear; mapeamento de entrada-saída que permite que os pesos sinápticos da rede sejam modificados para minimizar a diferença entre a resposta desejada e a resposta real da rede o que necessita que o treinamento seja repetido para muitos conjuntos diferentes até que a rede alcance um estado estável, sem que os pesos sinápticos sejam modificados significativamente; adaptabilidade para um ambiente não-estacionário, a rede pode modificar seus pesos em tempo real; resposta a evidências que traz a informação sobre a confiança na decisão tomada; informação contextual onde cada neurônio é potencialmente afetado pela atividade de todos os neurônios da rede; tolerante a falhas tal que se implementada na forma física (*hardware*) resultando em um neurônio ou conexão danificado, seu desempenho diminuiu suavemente e não gravemente; implementação VLSI (*very-large-scale-integration*) que faz a rede neural ser rápida na computação de certas tarefas; uniformidade de análise e projeto que apresenta a mesma notação em todos os domínios com aplicação de redes neurais; e a analogia neurobiológica onde o estudo da neurobiologia pode ser auxiliado por redes neurais no estudo de fenômenos, assim como ela pode auxiliar as redes neurais na solução de problemas mais complexos (Haykin, 2001).

#### 3.1.1 Neurônio artificial

Como dito anteriormente, os neurônios são células computacionais simples em que apenas um neurônio k pode ser definido matematicamente com um conjunto de duas equações:

$$\mu_k = \sum_{j=1}^{m} w_{kj} x_j , \quad y_k = \phi(\mu_k + b_k)$$
(15)

onde  $x_j$  são as entradas do neurônio,  $w_{kj}$  são os pesos do neurônio,  $\mu_k$  é a saída do combinador linear de entrada. Na segunda equação têm-se  $b_k$  como bias (viés), o  $\phi$  como função de ativação e  $y_k$  é a saída do neurônio (Haykin, 2001).

A função de ativação serve para restringir a amplitude de saída do neurônio e pode ser normaliza entre [0,+1] (sigmóide) e [-1,+1] (tangente hiberbólica). Há também a função de ativação ReLu (ativação linear retificada) que faz todo valor negativo ser zero e os valores positivos serem os máximos  $[0,\infty]$ . O *bias* serve para aumentar ou diminuir a entrada da função de ativação (Haykin, 2001).

## 3.1.2 Perceptron

Em 1958, Frank Rosenblatt introduziu uma nova abordagem para o reconhecimento de padrões, o *perceptron*. O *perceptron* tem como objetivo classificar um conjunto de estímulos aplicados (entradas) em uma de duas classes. Em sua forma mais simples, de duas variáveis, há duas regiões separadas por um hiperplano apresentada na figura 22 e definido pela equação 16.

$$\sum_{i=1}^{\mathbf{m}} w_i x_i + b = 0 \tag{16}$$

onde  $x_i$  são as entradas do neurônio,  $w_i$  são os pesos do neurônio e b é o bias.

Figura 22 - Regiões de classes divididas por um hiperplano



Legenda: Divisões entre as classes, classe 1 à esquerda e classe 2 à direita. Fonte: Haykin, 2001, p. 163. Adaptado pelo autor.

Neste caso, o *perceptron* aprende com um conjunto de treinamento composto por ambas as classes, quando ele classifica corretamente, seu peso não é corrigido, entretanto quando ele erra, o peso é corrigido pela equação 17:

$$w(n+1) = w(n) \pm \eta(n)x(n)$$
 (17)

onde n é a n-ésima iteração, w(n) é o peso na n-ésima iteração,  $\eta$  é o parâmetro da taxa de aprendizagem e x(n) é a entrada na n-ésima. Quando x(n) pertence à classe 1, o sinal é positivo, quando pertence à classe 2 é negativo.

A regra da aprendizagem por correção de erro é apresentada na equação 18:

$$w(n+1) = w(n) + \eta[d(n) - y(n)]x(n)$$
(18)

onde d(n) é a resposta desejada, y(n) é a resposta do perceptron e [d(n) - y(n)] é um sinal de erro.

Na figura 22, as duas classes são linearmente separáveis, ou seja, elas podem ser

divididas apenas como uma linha reta (hiperplano). Se essas classes não fossem separadas por uma linha reta, apresentassem curvas, o *perceptron* não funcionaria corretamente (Haykin, 2001). Para resolver esse problema mais complexo, foi desenvolvido o *Multi Layer Perceptron* (MLP, *perceptron* de múltiplas camadas) (Haykin, 2001).

#### 3.1.3 Multi Layer Perceptron

O *perceptron* de múltiplas camadas é uma generalização do *perceptron* de camada única e ele consiste em uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. A figura 23 apresenta um exemplo de MLP com duas camadas ocultas.

Figura 23 - Exemplo de Multi Layer Perceptron



Legenda: MLP com duas camadas ocultas. Fonte: Haykin, 2001, p. 186. Adaptado pelo autor.

A MLP apresenta uma função de ativação não-linear suave, seus neurônios ocultos fazem a rede a aprender tarefas complexas extraindo características mais significativas e sua rede tem alto grau de conectividade (Haykin, 2001).

Sua aprendizagem supervisionada utiliza o algoritmo de retropropagação de erro (*error back-propagation*) que é baseado na regra de aprendizagem por correção de erro. Esse algoritmo possui dois passos, para frente, propagação e para trás, retropropagação. Na propagação, os pesos são fixos e o vetor de entrada é aplicado sendo propagado por todas as camadas da rede, produzindo uma resposta da rede. Na retropropagação, a resposta da rede é subtraída da resposta desejada produzindo um sinal de erro que é propagado para trás ajustando os pesos da rede com uma regra de correção de erro. Esse processo de aprendiagem é chamado de aprendizagem por retropropagação (Haykin, 2001).

O algoritmo de retropropagação utiliza a função custo ou índice de desempenho

que é o valor instantâneo da energia do erro dos neurônios da camada de saída definido pela equação 19:

$$\varepsilon(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \tag{19}$$

onde  $e_j(n)$  é o sinal de erro e C inclui todos os neurônios da camada de saída da rede. A correção do peso  $\Delta w_{ji}(n)$  é proporcional à derivada parcial da equação 20:

$$\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} = \frac{\partial \varepsilon(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)}$$
(20)

onde  $\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)}$  é o fator sensibilidade que determina a direção de busca no espaços dos pesos,  $y_j(n)$  é o sinal funcional definido pela equação 21:

$$y_j(n) = \phi(v_j(n)) \tag{21}$$

e  $v_j(n)$  é o campo local induzido definido pela equação 22:

$$v_j(n) = \sum_{i=0}^{M} w_{ji}(n) y_i(n)$$
 (22)

onde m é o número total de entradas (sem bias) e o peso  $w_{j0}$  é bias  $b_j$ .

A partir disso, a correção dos pesos é definida pela regra delta definida na equação 23:

$$\Delta w_{ji}(n) = -\eta \frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} \tag{23}$$

onde  $\eta$  é o parâmetro da taxa de aprendizagem. Essa equação demonstra que o processo tem como objetivo calcular o gradiente do erro em relação aos pesos até minimizar o erro, sendo necessário utilizar um critério de parada para encerrar as iterações, ou seja, o treinamento da rede (Haykin, 2001).

## 3.1.4 Algoritmo RPROP

O RPROP é um algoritmo de retropopagação que significa "propagação resiliente" que utiliza uma adaptação direta de passo de peso com base nas informações do gradiente local. Cada peso é atualizado com seu valor individual  $\Delta_{ij}$  que determina o tamanho da atualização de peso, sendo que ele evolui adaptativamente durante o processo de aprendizagem com base na visão local na função de erro (Riedmiller; Braun, 1993). A aprendizagem ocorre como está na equação 24:

$$\Delta_{ij}^{(n)} = \begin{cases} \eta^+ \Delta_{ij}^{(n-1)}, se \ \frac{\partial \varepsilon}{\partial w_{ji}}^{(n-1)} \frac{\partial \varepsilon}{\partial w_{ji}}^{(n)} > 0\\ \eta^- \Delta_{ij}^{(n-1)}, se \ \frac{\partial \varepsilon}{\partial w_{ji}}^{(n-1)} \frac{\partial \varepsilon}{\partial w_{ji}}^{(n)} < 0 \end{cases}$$
(24)

onde  $0 < \eta^- < 1 < \eta^+$ . Depois de adaptado o valor da atualização de cada peso, se a derivada for positiva, o peso é diminuído pelo valor da atualização, se a derivada for negativa, o peso é adicionado pelo valor da atualização como mostra a equação 25:

$$\Delta w_{ij}^{(n)} = \begin{cases} -\Delta_{ij}^{(n-1)}, se \ \frac{\partial \varepsilon}{\partial w_{ji}}^{(n)} > 0 \\ +\Delta_{ij}^{(n-1)}, se \ \frac{\partial \varepsilon}{\partial w_{ji}}^{(n)} < 0 \end{cases}$$
(25)

Existe uma exceção quando a derivada parcial muda de sinal, ou seja, o passo anterior é muito grande e o mínimo foi perdido, a atualização do peso anterior é revertida como na equação 26:

$$\Delta w_{ij}^{(n)} = -\Delta w_{ij}^{(n-1)}, \ se \ \frac{\partial \varepsilon}{\partial w_{ji}}^{(n-1)} \frac{\partial \varepsilon}{\partial w_{ji}}^{(n)} < 0$$
(26)

Com essa reversão, pode-se supor que na etapa seguinte, a derivada mude de sinal novamente, o que não ocorre devido ao algoritmo não realizar uma nova adpatação na próxima etapa quando ocorre essa exceção. Os valores de atualização e os pesos são alterados toda vez que todo o conjunto de padrões é apresentado uma vez à rede (aprendizado por época) (Riedmiller; Braun, 1993).

#### 3.1.5 Algoritmo ADAM

O algoritmo ADAM (*adaptive moment estimation*) (Kingma; Ba, 2015) é um algoritmo de otimização estocástico com vantagens de só ter gradientes de primeira ordem e a utilização de pouca memória. Esse algoritmo combina as vantagens das propriedades de dois algoritmos: AdaGrad (*Adaptive Gradient Algorithm*) e RMSProp (*Root Mean Square Propagation*).

O ADAM apresenta a taxa de aprendizagem,  $\alpha$ , uma função ruído  $f(\theta)$  que é diferenciável, o parâmetro  $\theta$ , dois hiperparâmetros  $\beta_1, \beta_2$  no intervalo de [0, 1), o gradiente da função ruído,  $g_t = \nabla_{\theta} f_t(\theta)$  e as médias móveis exponenciais do gradiente  $(m_t)$  e do gradiente quadrado  $(v_t)$ . A aprendizagem ocorre com  $m_t$  e  $v_t$  iguais a zero, então eles são atualizados como nas equações 27 e 28:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \tag{27}$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \tag{28}$$

Na sequência, há uma correção de viés de  $m_t$  e  $v_t$  apresentado nas equações 29 e 31:

$$\hat{m}_t = \frac{m_t}{(1 - \beta_1^t)}$$
(29)

$$\hat{v}_t = \frac{v_t}{(1 - \beta_2^t)} \tag{30}$$

Por último, há a atualização do parâmtro  $\theta$  apresentado na equação :

$$\theta_t = \theta_{t-1} - \alpha \frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon} \tag{31}$$

onde  $\epsilon$  é um número muito pequeno que serve para evitar a divisão por zero. Então a correção ocorre pela equação 32:

$$\Delta \theta_t = -\alpha \frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon} \tag{32}$$

#### 3.1.6 Validação Cruzada

A validação cruzada é uma ferramenta que juntamente com a aprendizagem por retropropagação, pode auxiliar na busca por uma melhor eficiência, melhorando a estatística e a generalização em conjuntos com muitos dados. Há a divisão do conjunto de dados em dois conjuntos, o conjunto de treinamento e o de teste, o conjunto de treinamento é dividido ainda em mais dois conjuntos, o conjunto de estimação que seleciona o modelo e o conjunto de validação que valida o modelo.

Essa divisão tem como objetivo realizar a validação com um conjunto de dados diferentes daqueles que foram usados para estimar os parâmetros e o conjunto de teste mede o desempenho de generalização do modelo para que não haja um ajuste em excesso (*overfitting*) com o conjunto de validação (Haykin, 2001).

O método de validação cruzada múltipla k-fold (Raschka, 2020) permite dividir o conjunto de dados em k subconjuntos, então o treinamento é realizado com todos os subconjuntos, menos em 1 (k - 1) onde este é medido o erro da validação. Esse procedimento é repetido k vezes com subconjuntos diferentes. A figura 24 apresenta o método k-fold para k = 5. O desempenho é avaliado pela média quadrática do erro na validação. Este método apresenta grande vantagem quando há pouca quantidade de exemplos rotulados, porém requer um maior tempo de treinamento já que o modelo é treinado k vezes (Haykin, 2001).





Legenda: Nesse exemplo, k = 5, o quadrado azul representa a validação e o quadrado cinza o treinamento.

Fonte: Raschka, 2020, p. 25. Adaptado pelo autor.

## 4 ALGORITMO DOS ANÉIS DE ENERGIA (RINGERS)

### 4.1 NeuralRinger

O NeuralRinger (Seixas et al., 1996) é um algoritmo que emprega a soma de energia em anéis concêntricos à posição de incidência da partícula na célula mais energética, porém esses anéis não são circulares, eles apresentam formato retangular segmentado no plano  $\eta \ge \phi$  como mostram a figura 25 e a figura 26. Na figura 25, vê-se a divisão por anéis de cada camada dos calorímetros ilustrando uma região candidata nos dois calorímetros. Na figura 26, vê-se a região candidata em planos em diferentes camadas dos calorímetros. O calorímetro eletromagnético é dividido em 4 camadas: Pre-sample com 8 anéis, EM1 com 64 anéis, EM2 e EM3, ambas com 8 anéis. O calorímetro hadrônico é dividido em 3 camadas: HAD1, HAD2 e HAD3 com 4 anéis em cada camada. Os anéis dos dois calorímetros juntos, totalizam 100 anéis. A tabela 1 apresenta a quantidade de anéis por camada do NeuralRinger. As figuras 27 e 28 mostram o perfil de energia dos anéis do NeuralRinger de elétrons e de jatos respectivamente.

O NeuralRinger opera seguindo esses passos (Pinto, 2022):

- com a posição da *hot cell* (célula mais energética) da EM2 ( $\eta_{cluster}, \phi_{cluster}$ ), utiliza-se o refinamento do baricentro de energia na *l*-ésima camada obtendo-se todas as células dentro da janela retangular de busca que possui os limites  $\eta_{cluster} \pm 0, 2, \phi_{cluster} \pm 0, 2;$
- é obtido a posição central da célula mais energética para todas as camadas  $(\eta_{hot,l}, \phi_{hot,l})$ ;
- forma-se o anel  $R_{n,l}$  com todas as células  $c_{n,l}$ , em que n é dado pela equação 33:

$$n = max(\frac{\eta_{i,l} - \eta_{hot,l}}{h_{\eta,i}}, \frac{\phi_{i,l} - \phi_{hot,l}}{h_{\phi,i}}) \forall c_{i,l}$$

$$(33)$$

onde  $\eta_{i,l}$  é o centro da célula  $c_{i,l}$  e  $h_{\eta,i}$  é o passo em  $\eta$  para cada camada l (tabela 1), análogo para  $\phi$ ;

•  $r_{n,l}$  é a variável que representa, aproximadamente, a energia transversa do chuveiro depositada na região do anel, dada pela equação 34:

$$r_{n,l} = \frac{\sum_{i=o}^{\forall c_{i,l} \in R_{n,l}} E_{i,l}}{\cosh|\eta_{hot,l}|}$$
(34)

onde  $E_{i,l}$  é a energia da célula  $c_{i,l}$ .

Após o comissionamento do ATLAS em 2017, o *NeuralRinger* entrou em operação no *Trigger* HLT na etapa *FastCalo* para elétrons acima de 15 GeV (ATLAS Collaboration,

Figura 25 - Anéis do NeuralRinger



Legenda: Anéis do NeuralRinger por camadas divididas nos calorímetros eletromagnético (a) e hadrônico (b). A célula vermelha representa a célula mais energética (hot cell,  $C_{hot,l}$ ), ou seja, onde houve o depósito de maior energia. As células vizinhas  $(R_{n,l})$  em branco e as demais células  $(C_{i,l})$  em preto. Os eixos  $\eta \in \phi$  estão no plano horizontal e vertical do corte de segmentação, respectivamente. Fonte: Pinto, 2022, p. 69. Adaptado pelo autor.

Tabela 1 - Número de anéis e passo por camada do NeuralRinger.

Camada	Número de anéis	$h_{\eta,i}$	$h_{\phi,i}$
$_{\rm PS}$	8	0,025	$^{0,1}$
EM1	64	0,003	$^{0,1}$
EM2	8	0,025	0,025
EM3	8	0,050	0,025
HAD1	4	$^{0,1}$	$^{0,1}$
HAD2	4	$^{0,1}$	$^{0,1}$
HAD3	4	0,2	$^{0,1}$

Fonte: Pinto, 2022, p. 207; Freund, 2018, p. 112

2020), substituindo a estratégia de cortes rígidos (*Cutbased* ou *noringer*) do antigo algoritmo T2Calo que estava em operação (Simas Filho, 2010). O algoritmo *Cutbased* tem



Figura 26 - Anéis do NeuralRinger por anéis em plano

Legenda: Pré-amostrador, segunda camada do EM, terceira camada do EM e primeira camada do HAD. Os eixos  $\eta \in \phi$  estão no plano horizontal e vertical do corte de segmentação respectivamente. Os anéis formam-se a partir da *hot cell* (vermelho) sendo o primeiro anel, depois formam quadrados em volta dela (branco) formando o segundo anel e assim por diante (intercalando as cores pretas e brancas).

Fonte: Anjos, 2006, p. 195.



Figura 27 - Perfil de energia dos anéis do NeuralRinger para elétrons

Legenda: Elétrons (colisões). Fonte: Moura Junior, 2022, p. 8.

como estratégia aplicar cortes sequenciais com as seguintes variáveis em ordem:  $R_{\eta}$ ,  $E_{ratio}$ ,



Figura 28 - Perfil de energia dos anéis do NeuralRinger para jatos

Legenda: Jatos (colisões). Fonte: Moura Junior, 2022, p. 8.

 $E_{T,EM} \in R_{had}$ <sup>7</sup> (Araújo, 2019). Como ressaltado anteriormente, o espaço de fase (*ensem-ble*) é dividido em um plano  $E_T \ge \eta$ . A tabela 2 apresenta as regiões do espaço de fase do NeuralRinger assim como o modelo que utiliza outras variáveis de shower shape e os números dentro das chaves representam os índices correspondentes a uma matriz do espaço de fase com o início do índice em 0.

Tabela 2 - Regiões do espaço de fase do NeuralRinger.

Nome da região	Região	$15 < E_T < 20$	$20 < E_T < 30$	$30 < E_T < 40$	$40 < E_T < 50$	$50 < E_T$
Barril	$0,00 <  \eta  < 0.80$	[0,0]	[0,1]	[0,2]	[0,3]	[0,4]
Barril estendido	$0,\!80 <  \eta  < 1,\!37$	[1,0]	[1,1]	[1,2]	[1,3]	[1, 4]
Crack	$1,37 <  \eta  < 1,54$	[2,0]	[2,1]	[2,2]	[2,3]	[2,4]
Tampa	$1,54 <  \eta  < 2,37$	[3,0]	[3,1]	[3,2]	[3,3]	[3,4]
Tampa estendida	$2,37 <  \eta  < 2,50$	[4,0]	[4,1]	[4,2]	[4,3]	[4, 4]

Legenda: As energias transversas  $(E_T)$  estão em GeV. Fonte: O autor, 2024.

O NeuralRinger utiliza os seguintes parâmetros como quantitativos para avaliar o desempenho (figuras de mérito): probabilidade de detecção  $(P_D)$ , probabilidade de falso alarme  $(F_A)$  ou eficiência de background  $(E_B)$  e índice soma-produto (SP). O índice soma-produto está definido na equação 35. Os pontos de operação utilizados no NeuralRinger foram: lhtight, lhmedium, lhloose e lhveryloose.

$$SP = \sqrt{\sqrt{P_D(1 - E_B)} \frac{P_D + (1 - E_B)}{2}}$$
(35)

 $<sup>^7</sup>$  O  $R_{had}$  é definido pela razão da energia transversa hadrônica pela energia transversa eletromagnética. Essa variável não está disponível na etapa FastCalo do HLT.

O modelo do *NeuralRinger* utilizado no Run 2 foi o *NeuralRinger* com 100 anéis, ou seja, uma rede neural do tipo MLP totalmente conectada com uma topologia de 100 entradas, uma camada escondida com um número definido de neurônios que usam tangente hiperbólica como função de ativação e uma saída com um neurônio (Pinto, 2022).

O ajuste das redes, iniciado aleatoriamente, ocorreu com o algoritmo RPROP (Riedmiller; Braun, 1993), a função de custo foi o Erro Quadrático Médio (MSE) e o critérito de parada foi o  $SP_{max}$  que é a melhor relação entre  $P_D$  e  $E_B$  considerando o ponto de operação. A normalização empregada foi a divisão do valor de cada anel  $(r_{n,l})$ pelo módulo da soma do valor de todos os anéis (Pinto, 2022).

A validação cruzada foi utilizada com o método k-fold estratificado (k=10) em que os dados foram divididos em 10 partições e foram sorteados 10 vezes. Para o conjunto de validação foi utilizado o mesmo conjunto de teste, ou seja, para um sorteio, 90% dos dados foram para treino, 10% para validação("teste"). O processo de treinamento foi repetido 100 vezes para cada configuração, para evitar a performance subótima. Dessas 100 inicializações, a rede que obtém o maior índice SP, no treino e validação, é selecionada (Pinto, 2022).

Os valores de  $E_B$  e SP são obtidos para um determinado  $P_D$  de referência (dado pela resposta do algoritmo de cortes lineares da etapa rápida) que é calculado a partir da *Receiver Operating Characteristic Curve* (curva ROC)(Fawcett, 2006) do conjunto de validação para cada uma das 10 redes selecionadas realizado para todas as amostras. A curva ROC é um gráfico de duas dimensões em que no eixo Y estão os sinais positivos verdadeiros e no eixo X estão o falso alarme. Então, é obtida a flutuação estatística da validação cruzada para  $E_B$ , SP e um  $P_D$  de referência avaliado com o conjunto de validação (Pinto, 2022).

A conclusão da avaliação da topologia empregada foi que a melhor capacidade de generalização do modelo na camada escondida utilizava apenas 5 neurônios. Por último, é realizada a correção linear do efeito de empilhamento em função do  $P_D$  do *cut-based* para a região que está sendo avaliada (descrito na subseção 2.4.1) e houve a mudança da função de ativação do neurônio de saída que era tangente hiperbólica para linear (a função linear não altera a saída do neurônio), pois a função anterior fazia com que o ajuste apresentasse uma não linearidade na saída da rede neural. Vale ressaltar que o método *Tag and Probe* foi utilizado para seleção de sinal, ou seja, elétrons *probes* oriundos dos dados de Z→ee com  $E_T > 15$  GeV (Pinto, 2022).

Outras versões do *NeuralRinger* foram desenvolvidas por (Pinto, 2022) que envolviam aprendizado profundo como redes neurais convolucionais (CNN) e estratégias próximas à fusão de informação. A cada nova estratégia utilizando o *NeuralRinger*, foi dada uma sigla, denominada V com o número da estratégia, por exemplo, o procedimento descrito acima com 100 anéis era v8, pois foi o oitavo modelo desenvolvido.

### 4.2 Histórico do NeuralRinger

Os trabalhos envolvendo o *NeuralRinger*, iniciaram em 1996 (Seixas *et al.*, 1996) e a última contribuição é abordada neste trabalho até a sua publicação. Todos os trabalhos com o *NeuralRinger* foram dedicados para sua atuação no primeiro estágio de seleção do HLT, que corresponde atualmente a etapa *FastCalo*. Abaixo será descrito brevemente algumas das principais contribuições para o algoritmo do *NeuralRinger*.

O primeiro trabalho que orignou os *Ringers* (Seixas *et al.*, 1996), foi de autores que fizeram parte do projeto do calorímetro SPACAL que era um calorímetro projetado para aplicação em ambientes de alta taxa de colisões como o LHC. Ele tinha 155 células hexagonais que formamam sete anéis hexagonais concêntricos (Freund, 2018).

No trabalho de Anjos (Anjos, 2006), a simulação já apresentava a geometria do calorímetro do ATLAS, o que auxiliou a avaliar melhor a evolução do chuveiro. Os dados empregados possuíam amostras de decaimentos  $Z \rightarrow ee$  e 10 milhões de amostras de jatos duplos onde foram utilizados somente aqueles com energia de colisão superior a 25 GeV. Além disso, houve cortes que exigiam *clusters* eletromagnéticos de pelo menos 10 GeV na região  $|\eta| < 2, 5$ . isolamento eletromagnético de 4 GeV e isolamento hadrônico de 2 GeV. Ao final, sobraram 22000 elétrons e 7000 jatos onde metade serviu de conjunto de treino e o restante para avaliação de eficiência de classificação (Freund, 2018).

O trabalho fazia uma otimização por busca exaustiva por via de uma grade de cortes lineares sequências em 4 variáveis  $R_{\eta}$ ,  $E_{ratio}$ ,  $E_{T,EM}$  e  $E_{T,HAD1}$  que foi utilizada como referência. Houve adição de mais variáveis: 4 amostragens longitudinais no ECAL e 4 amostragens longitudinais no HCAL,  $w_{\eta^2}$  e vazamento lateral em  $\eta$  na EM2. Aplicou-se a Análise de Componentes Principais (PCA) que melhorou ligeiramente a base original. A análise de relevância mostrou que as cinco variáveis mais discriminantes foram em ordem decrescente:  $R_{\eta}$ ,  $E_{ratio}$ ,  $E_{EM1}$ ,  $w_{\eta^2}$  e  $E_{HAD1}$  (Freund, 2018).

Após a análise, houve a implementação do algoritmo de anelamento atendendo às necessidades de implementação do segundo nível de filtragem. Tal implementação guiou todas as outras versões do algoritmo de anelamento (Freund, 2018).

O trabalho de Torres (Torres, 2010) apresentava elétrons igualmente distrubuídos entre  $7 < E_T[GeV] < 80$  e jatos com mais de 17 GeV. Houve a seperação em dois conjuntos: um com e10 (470k elétrons e 315k jatos) e outro com e15*i* (140k elétrons e 13k jatos) que apresentavam isolamento eletromagnético em 3 GeV, hadrônico em 1 GeV e limite para vazamento hadrônico de 2 GeV (Freund, 2018).

O estudo de Torres foi o que introduziu o critério de parada da rede neural pelo critério SP que mostrou ser o melhor critério para discriminação. O treinamento foi com o RPROP com validação cruzada em 12 subconjuntos, com 6 para treino e 6 para teste/validação (mesmo conjunto). Com os dados de e15i utilizaram duas análises para obtenção de bases que compuseram o espaço de características via pré-processamentos
estatísticos PCA, Componentes Principais de Discriminação (PCD) e Análise de Componentes Independentes (ICA), segmentada e não-segmentada. Por último, Torres validou o algoritmo em raios cósmicos, onde mostrou que o algoritmo dos anéis apresentava capacidade superior ao *T2Calo* para rejeição de raios cósmicos (Freund, 2018).

O trabalho de Simas Filho (Simas Filho, 2010) se dedicou ao estudo do préprocessamento não-linear, com as projeções de base em cima dos anéis normalizados por norma-1 para eventos simulados e sequencial para os dados de colisão. Aplicaram-se três variantes de NLICA: *Post Nonlinear model* (PNL), SOM (extração do SOM) e ICA Local (com grupos obtidos via *k-means*) (Freund, 2018).

Simas Filho também propôs uma abordagem utilizando classificadores especialistas para cada camada longitudinal obtida pelo Algoritmo NeuralRinger. Para a saída final, o trabalho concatenou as saídas de cada um dos classificadores segmentados e os alimentou para uma rede MLP com duas camadas. Houve uma análise de relevância por camada que indicou maior relevância da camada EM1 pelo algoritmo ICA Local. Foi realizada uma análise de quadrante em função das variáveis  $\eta \in E_T$  entre o algoritmo NeuralRinger e o T2Calo que mostrou melhor performance do NeuralRinger na região do crack com elétrons de baixa energia (Freund, 2018).

O trabalho de Xavier (Xavier, 2011) foi o primeiro a ter a técnica de Tag and Prove utilzada para avaliar a performance do algoritmo NeuralRinger. Sua base de dados foram os eventos simulados com colisões próton-próton com energia de 14 TeV com a filtragem do L1Calo para as cadeias e10 e e22. O trabalho de Xavier, assim como os outros, obteve melhores resultados para o algoritmo do NeuralRinger (Freund, 2018).

O trabalho de Freund (Freund, 2018) teve como objetivo desenvolver o *Neu*ralRinger para seleção offline e avaliar o seu possível emprego na filtragem online. Seu trabalho juntamente com outros colaboradores fez o *NeuralRinger* ser oficialmente utilizado no *Trigger HLT* do ATLAS para elétrons acima de 15 GeV após o comissionamento de 2017.

O trabalho de Araújo (Araújo, 2019) teve como objetivo desenvolver o Neural-Ringer para seleção de elétrons abaixo de 15 GeV. Os eventos utilizados para treinamento possuiam elétrons do decaimento do méson  $J/\Psi$ , pois para a faixa de energia abaixo de 15 GeV, os elétrons desse decaimento são predominantes. Seu trabalho mostrou que o NeuralRinger apresenta melhores resultados, diminuindo o falso alarme por um fator 3 no critério Tight, ou seja, o falso alarme do NeuralRinger é um terço do falso alarme da estratégia atual.

O trabalho de Pinto (Pinto, 2022), além de auxiliar nos outros trabalhos, como de Freund e Araújo, ele desenvolveu várias versões do *NeuralRinger* para, principalmente, a *Run* 3 envolvendo redes convolucionais, redução de anéis e técnicas parecidas com fusão de informação. A abordagem do presente trabalho foi motivada por ele.

O trabalho de Ferreira (Ferreira, 2022) teve como objetivo desenvolver um

filtro *online* para região *forward* do ATLAS, onde não há reconstrução *online* para futuras aplicações. Foram utilizados modelos do *NeuralRinger* com MLP e CNN.

O presente trabalho explorou a área de fusão de informação com o *Neural-Ringer* e as variáveis de *shower shape* para energias acima de 15 GeV. Assim como os trabalhos anteriores, ele é o produto de uma grande colaboração entre diversos pesquisadores envolvendo universidades como UERJ, UFRJ, COPPE/UFRJ, UFBA, UFJF e *Sorbonne* (França).

## 5 VARIÁVEIS DE SHOWER SHAPE

Além da medida de energia obtida pelos anéis, há seis variáveis físicas que podem ser utilizadas na etapa rápida do *trigger* do ATLAS (*FastCalo*). O sinal é considerado como elétrons enquanto o *background* são jatos gadrônicos. Essas variáveis físicas são conhecidas como variáveis de *shower shape* e estão apresentadas abaixo:

*E<sub>ratio</sub>*, apresenta a razão entre o primeiro máximo de energia da camada EM1 menos o segundo máximo da mesma camada sobre a soma de ambos, dada pela equação 36;

$$E_{ratio} = \frac{E_{Em1}^{max} - E_{Em1}^{2ndmax}}{E_{Em1}^{max} + E_{Em1}^{2ndmax}}$$
(36)

A distribuição da variável  $E_{ratio}$  está apresentada na figura 29

Figura 29 - Distribuição  $E_{ratio}$ 

. -



Legenda: Sinal (preto) e background (vermelho) da distribuição  $E_{ratio}$ . Fonte: Araújo, 2019, p. 29.

•  $R_{\eta}$  é a razão de energia das células 3 x 7 para as células 7 x 7 centralizadas no depósito de maior energia do chuveiro eletromagnético na camada EM2, dada pela equação 37;

$$R_{\eta} = \frac{E_{Em2}^{3x/\ell}}{E_{Em2}^{7x7}} \tag{37}$$

A distribuição da variável  $R_{\eta}$  está apresentada na figura 30. Vale ressaltar que devido à reconstrução de energia, algumas células podem apresentar energia negativa por causa de ruído, subtração de *pileup* e calibração, a razão das variáveis, como a  $R_{\eta}$ , pode ser um pouco diferente de 1.

Figura 30 - Distribuição  $R_{\eta}$ 



Legenda: Sinal (preto) e *background* (vermelho) da distribuição  $R_{\eta}$ . Fonte: Araújo, 2019, p. 29.

•  $f_1$  é a fração de energia entre a energia total depositada na camada EM1 sobre a energia total medida no calorímetro eletromagnético para o chuveiro EM que está sendo avaliado (identificado), dada pela equação 38;

$$f_1 = \frac{E_{Em1}^{total}}{E_{Em}^{total}} \tag{38}$$

•  $f_3$  é a fração de energia entre a energia total depositada na camada EM3 sobre a energia total medida no calorímetro eletromagnético para o chuveiro EM que está sendo avaliado (identificado), dada pela equação 39;

$$f_3 = \frac{E_{Em3}^{total}}{E_{Em}^{total}} \tag{39}$$

A distribuição da variável  $f_3$  está apresentada na figura 31

•  $w_{\eta^2}$  é a largura lateral do chuveiro na camada EM2, dada pela equação 40;

Figura 31 - Distribuição  $f_3$ 



Legenda: Sinal (preto) e *background* (vermelho) da distribuição  $f_3$ . Fonte: Hanagaki *et al.*, 2022, p. 84.

$$w_{\eta^2} = \sqrt{\frac{\sum E_i \ \eta_i^2}{\sum E_i} - \left(\frac{\sum E_i \ \eta_i}{\sum E_i}\right)^2} \tag{40}$$

onde  $\eta_i$  é uma região de  $\eta$  e  $E_i$  é a energia correspondente a região de  $\eta_i$ . A distribuição da variável  $w_{\eta^2}$  está apresentada na figura 32

Figura 32 - Distribuição  $w_{n^2}$ 



Legenda: Sinal (preto) e background (vermelho) da distribuição  $w_{\eta^2}$ . Fonte: Hanagaki et al., 2022, p. 84.

•  $w_{stot}$ é a largura do chuveiro na camada EM1, dada pela equação 41;

$$w_{stot} = \sqrt{\frac{\sum E_i (i - i_{max})^2}{\sum E_i}} \tag{41}$$

onde i é o elemento que percorre todas as tiras na janela e  $i_{max}$  é o índice com maior energia na tira.

Houve a criação de um modelo de rede neural utilizando as 6 variáveis com os mesmos parâmetros que o modelo do *NeuralRinger* com 100 anéis por (Pinto, 2022) para realizar uma estratégia semelhante a fusão de informação chamada de V9, porém seus resultados não foram melhores que os do *NeuralRinger* com 100 anéis (V8).

A normalização das variáveis de *shower shape* para este trabalho, está presente na tabela 3, são as mesmas normalizações dos trabalhos Pinto, 2022 e Freund, 2018. A normalização dessas variáveis foi necessária para que elas tenham uma melhor resposta no modelo de rede neural.

Tabela 3 -	- Normanzaçao	das varaveis	ae	snower	snape.

Variável	Normalização
$E_{ratio}$	1,0
$R_{\eta}$	1,0
$f_1$	$0,\!6$
$f_3$	0,04
$w_{\eta^2}$	$0,\!4$
$w_{stot}$	1,0

Legenda: Normalização das variáveis de *shower shape* conforme Pinto, 2022 e Freund, 2018. Fonte: Pinto, 2022, p. 89

### 6 INEFICIÊNCIA NA IDENTIFICAÇÃO DOS ELÉTRONS BOOSTED

Foi verificado que o NeuralRinger apresentava ineficiência para elétrons boosted, como pode ser visto nas figuras 33a e 33b que apresentam as eficiênias offline para o momento transverso  $(p_T)$  do leading elétron (acima de 400 GeV) e  $\Delta R$  (abaixo de 0,4) para o par elétron-pósitron respectivamente para uma amostra de Monte Carlo de 2016 com elétrons boosted em  $Z^0 \rightarrow e^+e^-$ . Nessas figuras (33a e 33b) apresentam cadeias de processamento do NeuralRinger como e26, e as cadeias somente com o algoritmo anterior do Cutbase que utiliza algumas das variáveis do shower shape com a designação "noRinger". Vale ressaltar, a resiliência do Cutbase ao aumento de  $p_T$ , o que pode demonstrar que as variáveis de shower shape podem auxiliar os anéis de alguma forma, já que o NeuralRinger apresenta melhores resultados de forma geral em seu ensemble.

Figura 33 - Eficiências em  $p_T \in \Delta R$  para elétrons



Legenda: À esquerda, há o gráfico com a eficiência do NeuralRinger e do método de cortes lineares (noRinger) em  $p_T$  e na direita, em  $\Delta R$ . Fonte: Carlino *et al.*, 2018, p. 11.

Para solucionar essa ineficiência, foram desenvolvidas estratégias que envolviam diminuição de anéis, redes neurais convolucionais, fusão de informação e uma técnica para selecionar apenas os elétrons *boosted* separando-os dos não *boosted*. A figura 34 apresenta o perfil de energia dos anéis do *NeuralRinger* para elétrons *Boosted*, em que se percebe uma diferença significativa na deposição de energia nos anéis finais da camada EM2.

A diminuição de anéis do NeuralRinger, mostrou-se bastante eficaz fazendo



Figura 34 - Perfil de energia dos anéis do NeuralRinger para elétrons Boosted

Legenda: Elétrons Boosted (Monte Carlo). Fonte: Moura Junior, 2022, p. 8.

com que a  $V8^8$ , com 100 anéis, fosse substituída pelo novo modelo, V12 (Pinto, 2022), com 50 anéis, ou seja, com metade dos anéis e essa metade se refere à seleção dos primeiros anéis de cada camada, por exemplo, na EM1 com 64 anéis, são selecionados somente os 32 primeiros. Dessa forma, analisando conjuntamente as figuras 27, 34 e 35, a diferença apresentada dos elétrons *Boosted* é diminuida, o que pode facilitar a identificação correta da partícula como elétron, não jato. Este trabalho será sobre a estratégia da fusão de informação utilizando o modelo do *NeuralRinger* com um modelo que utiliza as variáveis de *shower shape*.





Legenda: Elétrons Boosted (Monte Carlo). A parte laranja demonstra a parte de informação não utilizada pelo modelo com metade dos anéis, V12.

Fonte: Moura Junior, 2022, p. 8. Adaptado pelo autor.

<sup>&</sup>lt;sup>8</sup> Relembrando que a nomeação das versões do NeuralRinger são feitas a partir do desenvolvimento ordenado, ou seja, a versão V8 foi a oitava versão realizada, a V12, a décima segunda e assim por diante.

## 7 FUSÃO DE INFORMAÇÃO

A fusão de informação não é um conceito novo. O ser humano, até mesmo os animais, já tem utilizado essa técnica para desenvolver habilidades para classificação, por exemplo, para avaliar se o alimento está bom ou não para digestão; para isso, ele utiliza a visão, o olfato ou até mesmo o paladar, classificando assim se o alimento está comestível. Essas informações são analisadas em conjunto e a partir daí, ou seja, da fusão de informação, há a classificação (Liggins; Hall; Llinas., 2017).

Vale ressaltar que fusão de dados (*data fusion*) e fusão de informação não são sinônimos. A fusão de dados apresenta os dados sem nenhum tratamento, enquanto a fusão de informação já apresenta os dados processados (Castanedo, 2013).

Na fusão de dados, apesar de ser uma área multidisciplinar com várias subdivisões, as técnicas e os métodos referentes a ela podem ser divididos em cinco critéritos (Castanedo, 2013):

- relação entre os dados de entrada, podem ser: complementares, redundantes ou coperativos;
- relação entre os dados de entrada e os dados de saída devem ser as propostas por Dasarathy (Dasarathy, 1997);
- o nível dos dados empregados (nível abstrato) pode ser: dados brutos, sinais e características ou decisões;
- diferentes modos de fusão de dados definidos por JDL (*Joint Directors of Laborato*ries);
- a forma de arquitetura de fusão deve ser: centralizada, descentralizada, distribuída e hierárquica.

Cada uma dessas classificações será melhor discutida a seguir.

### 7.1 Classificação: dados de entrada

A relação dos dados de entrada pode ser de três formas:

- complementares: a informação de entrada representa diferentes partes de um objeto, obtendo no final uma informação mais completa do objeto analisado;
- redundantes: quando as informações de entrada não aumentam a confiança da informação final, ou seja, caso uma informação de entrada seja omitida, não há mudança na confiança dos dados;

 cooperativas: quando a informação combinada é mais complexa que a informação original;

A figura 36 apresenta as três classificações da fusão com base na entrada dos dados.

Figura 36 - Classificação da fusão com base na entrada de dados



Legenda: À esquerda, fusão complementar, no centro fusão redundante e à direita, fusão cooperativa. Fonte: Castanedo, 2013, p. 3.

### 7.2 Classificação: Dasarathy

Dasarathy (Dasarathy, 1997) dividiu em 5 categorias a relação entre os dados de entrada (input) e os dados de saída (output):

- data in-data out (DAI-DAO): os dados de entrada são dados brutos que acabaram de ser coletados e estão sendo processados sendo que os dados de saída são da mesma natureza, mas normalmente mais confiáveis ou precisos;
- data in-feature out (DAI-FEO): os dados brutos são extraídos para características que descrevem um objeto;
- *feature in-feature out* (FEI-FEO): as entradas e saídas são características, mas ao longo do processo, elas são melhoradas, refinadas para se obter novas características;
- feature in-decision out (FEI-DEO): as entradas são características e a saída é uma decisão;

• *decision in-decision out* (DEI-DEO): as entradas e as saídas são uma decisão, ou seja, é uma fusão de decisões.

A figura 37 apresenta as cinco classificações da fusão de Dasarathy.

Figura 37 - Classificação de Dasarathy



Legenda: As cinco classificações de Dasarathy. Fonte: Castanedo, 2013, p. 3.

### 7.3 Classificação: nível abstrato

A fusão de informação apresenta três níveis abstratos: os níveis das medidas, das características e das decisões. A fusão de dados também pode apresentar quatro níveis abstratos:

- nível baixo de fusão (medidas): os dados brutos de entrada são processados pela fusão de dados que faz os dados saírem mais precisos ou com menos ruído;
- nível médio de fusão (características): características são fusionadas para obter novas características;

- nível alto de fusão (decisões): utiliza representações simbólicas (podendo ser decisões) que combinadas obtém-se uma decisão mais precisa;
- nível múltiplo de fusão: nesse nível, há a combinação de diferentes níves de abstração, ou seja, uma medida é combinada com uma característica para obter uma decisão.

Além dessa classificação, há outra que apresenta quatro subdivisões, são elas:

- nível de sinal: sinal oriundo diretamente dos sensores;
- nível de pixel: opera no nível de imagens e pode ser usado para melhorar o processamento de imagens;
- característica: emprega as características retiradas das imagens ou sinais;
- simbólica: informação no nível simbólico, também conhecido como nível de decisão.

## 7.4 Classificação: Joint Directors of Laboratories (JDL)

A organização JDL e a *American Department of Defense* (DoD) classificaram o processo de fusão de dados (a classificação mais conhecida conceitualmente na sociedade de fusão dados (Krushnasamy; Rashinkar, 2017)) em cinco níveis, são eles:

- nível 0 pré-processamento de origem: menor nível de fusão de dados que inclui a fusão no nível de sinal e pixel. Esse nível reduz os dados e mantém a informação acessível para os outros níveis do processo;
- nível 1 refinamento de objeto: refinamento do nível anterior, dentre os processos que ocorrem neste nível são alinhamento, associação, correlação, agrupamento (*clustering*) ou técnicas de agrupamento, estimativa de estado, remoção de falsos positivos, fusão de identidade e combinação de características que foram extraídas de imagens. A saída corresponde à discriminação do objeto (classificação e identificação) transformando os dados de entrada em uma estrutura consistente de dados;
- nível 2 avaliação da situação: tem como função identificar as situações prováveis em relação aos eventos observados e aos dados obtidos tendo como objetivo identificar atividades ou eventos significativos. As relações de proximidade são valorizadas para determinar a importância dos objetos em um ambiente específico;
- nível 3 avaliação de impacto: avalia as atividades realizadas no nível 2 e faz futuras projeções para identificar possíveis riscos, vulnerabilidades e operações oportunas;

• nível 4 - refinamento do processo: melhora o processamento de todos os níveis anteriores com gerenciamento de recursos e sensores.

A fusão de dados de alto nível geralmente inicia no nível 2. A figura 38 apresenta as cinco classificações da fusão de JDL. A diferença das classificações de Dasarathy e JDL é que Dasarathy percebe a relação entre as técnicas de fusão e os dados empregados enquanto JDL tem a pespectiva do *design* dos sistemas de fusão.

Figura 38 - Classificação de JDL



Legenda: As cinco classificações de JDL. Fonte: Castanedo, 2013, p. 4.

## 7.5 Classificação: arquitetura de fusão

A arquitetura de fusão representa uma classificação com base em como os dados podem ser processados. Há quatro tipos de arquiteturas: centralizada, descentralizada, distribuída e hierárquica. Essas arquiteturas serão apresentadas a seguir:

- arquitetura centralizada: nessa arquitetura, a fusão de dados ocorre em um processador central que recebe os dados brutos de todas as entradas. Um grande problema dessa arquitetura é que o tempo em que a informação é transmitida pelas diversas fontes é significativo, afetando os resultados, além disso, há necessidade de uma alta largura de banda para enviar todos os dados brutos pela rede. A figura 39 apresenta o esquema da arquitetura centralizada;
- arquitetura descentralizada: apresenta uma rede de nós onde cada um deles apresenta capacidades de processamento diferentes, não existindo um único ponto de fusão de dados que ocorre de maneira autônoma de seus pares. A maior desvantagem da arquitetura descentralizada é o custo de comunicação devido aos nós podendo sofrer problemas de escala. A figura 40 apresenta o esquema da arquitetura descentralizada;

### Figura 39 - Arquitetura centralizada



Legenda: Dados brutos são enviados pelas fontes para um processador central. Fonte: Castanedo, 2013, p. 6.

Figura 40 - Arquitetura descentralizada



Legenda: Uma rede de nós processa a informação de maneira autônoma. Fonte: Castanedo, 2013, p. 6.

- arquitetura distribuída: as informações de entrada são processadas de forma independente para que elas sejam enviadas ao nó de fusão, ou seja, a associação de dados e a estimativas são realizadas em cada uma das origens tendo elas apenas uma visualização local e elas são enviadas para o processo de fusão que apresentará uma visão global do processo. Esse tipo de arquitetura de fusão pode oferecer muitas opções como vários nós de fusão intermediários. A figura 41 apresenta o esquema da arquitetura distribuída;
- arquitetura hierárquica: combinação de nós descentralizados e distribuídos em que a fusão de dados é realizada em diferentes níveis de hierarquia.

Diferentemente das arquiteruras centralizadas e descentralizadas, a arquitetura distribuída apresenta vantagens em relação à redução dos custos computacionais e de comunicação, porém como são realizadas as estimativas fundidas, ou seja, se apresenta uma tendência para algum dos modelos fusionados, isso reflete no desempenho do modelo.

#### Figura 41 - Arquitetura distribuída



Legenda: Três entradas que são processadas e enviadas ao nó de fusão que utiliza as informações processadas como entrada.

Fonte: Castanedo, 2013, p. 6.

### 7.6 Escolha do modelo de fusão de informação

Atualmente, a fusão de informação tem se desenvolvido em áreas com utilização de multisensores como em aplicações militares (Martin; Chang, 2005; Dou *et al.*, 2018), robótica (Cheng-HungChen; Naidu, 2017), monitoriamento ambiental (Hem; Brekke, 2022) e processos de localização facial (Belaroussi; Prevost; Milgram, 2006), entre outros. Exemplos do emprego de fusão de informação, tem-se no trabalho de Chen e Jahanshahi (Chen; Jahanshahi, 2018), que utiliza a fusão de informação por vídeo para detectar rachaduras em componentes de uma usina nuclear, no trabalho de Jie Liu (Liu *et al.*, 2022), que utiliza a fusão para caracterizar drogas e proteínas ligadas à doença de Parkinson e também no trabalho de Lan Liu (Liu *et al.*, 2021), que por meio da fusão, faz o monitoramento de nuvens de cinzas vulcânicas. Em Física de Altas Energias, também não é algo novo empregar a fusão de informação, no trabalho de Gama (Gama, 2017), utiliza-se para atenuar a taxa de falso alarme dos múons com a informação proveniente do calorímetro hadrônico (especificamente, TileCal) e das câmaras de múons.

O uso de redes neurais para realizar a fusão de informação se deve ao seu caráter discriminatório para identificar padrões em sistemas com um grande número de variáveis e dados.

Considerando o ambiente do HLT do *Trigger*, onde os dados já passaram pela L1 do mesmo, a classificação em relação à entrada, deve ser complementar, pois temos os anéis do *NeuralRinger* e do *shower shape* em que ambos apresentam informações diferentes que podem ser complementares. Para a classificação de Darasathy, será FEI-DEO, ou seja, entrada de características (anéis de energia ou variáveis de *shower shape*) e a saída, uma decisão (elétron ou não).

Para classificação abstrata tem-se o nível médio de fusão, pois as informações no nível das características serão fusionadas. Seria possível fusionar as decisões dos modelos, porém diminuiria sua capacidade de lidar com a informação, podendo fazer com que o modelo realizasse uma fusão de informação redundante devido à melhor resposta ser do *NeuralRinger*, o que faria o modelo das variáveis tradicionais do *shower shape* dispensável neste caso. Para a outra classificação abstrata (segunda classificação) seria o nível das características por fusionar esse tipo de dado.

A classificação JDL é a de nível 1 por combinar características fazendo a discriminação do objeto (elétron ou não). Para a arquitetura de fusão, será usada a distribuída, pois a arquitetura centralizada apresenta a necessidade de uma alta largura de banda e um tempo maior para o processamento de dados enquanto a descentralizada apresenta maiores custos em comunicação, lembrando que no ambiente do *Trigger* online, essas propriedades devem apresentar a menor taxa possível. A arquitetura hierárquica também foi descartada já que ela oferece a combinação das outras arquiteturas que apresentam desvantagens no contexto.

Adotamos uma fusão de informação com dois modelos já treinados, com seus pesos congelados e a remoção dos neurônios da camada de saída, onde ambos são conectados a uma camada escondida de fusão MLP e com uma única saída. Todos os modelos foram treinados com dados de 2017 com 13 TeV de energia de centro de massa, eles serão melhor descritos no capítulo 9. Essa estratégia já foi utilizada em (Pinto, 2022), porém não houve congelamento dos pesos e nem a utilização do modelo de metade dos anéis, que está apresentando melhores resultados. Os modelos escolhidos para a fusão foram o *NeuralRinger* com metade dos anéis e o modelo das variáveis tradicionais do *shower shape* com 6 variáveis físicas disponíveis.

Como foi dito anteriormente, os modelos foram treinados com dados de 2017 e após o treinamento, seus pesos foram congelados e sua camada de saída removida e introduzidos em uma MLP onde ela foi treinada com a informação proveniente dos modelos com os dados de 2017 para classificação de elétrons/ruído (jatos). O modelo de fusão realiza a tomada de decisão exclusivamente na camada MLP (fusão) que recebe a informação dos dois modelos, o modelo *NeuralRinger* e o modelo de variaveis de *shower shape*. A partir das informações recebidas dos modelos, a camada de fusão realiza a classificação da partícula em elétron ou não. O modelo de fusão de informação deste trabalho está apresentado na figura 42.

Figura 42 - Modelo de fusão de informação





Fonte: O autor, 2024.

# 8 MÉTODO UTILIZADO

Para realizar a fusão de informação com dois modelos de redes neurais, um com apenas anéis (*NeuralRinger*) e outro com apenas variáveis tradicionais do shower shape, no ambiente do trigger HLT, foi utilizado uma ensemble de 25 regiões ( $E_T \ge \eta$ ), validação cruzada (k-fold) em que k = 10 e o treinamento da rede em dados de colisão de 2017. Os dois outros modelos que já foram treinados, apresentavam os mesmos parâmetros já citados.

Especificamente para este modelo de fusão, foi utilizado o *TensorFlow* (TEN-SORFLOW, 2024) com entropia cruzada binária como função custo e o ADAM (Kingma; Ba, 2015) (*Adaptive Moment Estimation*) como algoritmo de otimização. A função de ativação dos neurônios foi por meio da ativação linear retificada (ReLU), menos no neurônio de saída que foi utilizada a função sigmoide. Vale ressaltar que houve a correção do efeito de empilhamento da mesma forma dos outros modelos.

Esses parâmetros foram os mesmos empregados em (Pinto, 2022), com a modificação do congelamento dos pesos dos modelos já treinados e com o fusionamento de modelos diferentes (*NeuralRinger* com metade dos anéis e modelos distintos de variáveis de *shower shape*).

## 9 DADOS E RESULTADOS

O processo de validação de novos modelos do *NeuralRinger* segue as seguintes etapas:

- tabela de  $P_D$  (probabilidade de detecção);
- curvas de eficiência (*Turn ons*);
- análise de quadrante.

Neste secção, iniciaremos falando dos dados utilizados, depois das tabelas de  $P_D$ , curvas de eficiência e análise de quadrante.

Vale ressaltar que os métodos empregados estão descritos no capítulo 8 e o modelo de fusão na seção 7.6 e apresentado na figura 42. Foram desenvolvidos dois modelos de fusão diferentes, um com as seis variáveis de *shower shape* e outro com apenas quatro variáveis.

### 9.1 Dados reais e simulados

Os dados reais utilizados para este trabalho foram coletados em 2017 na energia de centro de massa de 13 TeV pelo ponto de operação *lhmedium* com EGAM1 para sinal e EGAM7 para *background*. O EGAM1 para sinal significa que a pré-seleção de eventos com elétrons compatíveis com o decaimento do bóson Z, exigindo que a massa invariante de um par, via soma dos quadrimomentos, seja superior a 50 GeV com um dos seguintes critéritos:

- dois elétrons centrais ( $|\eta| < 2, 5$ ) de carga elétrica oposta (OS), um deles aceito pelo ponto de operação *lhtight* ou *CutBased* (estratégia de corte linear) e  $p_T > 24, 5$ GeV e outro aceito pelo ponto de operação *medium* por ao menos uma das seleções citadas e  $p_T > 19, 5$  GeV;
- dois elétrons centrais OS pelo ponto de operação *lhmedium* ou *CutBased* com  $E_T > 19, 5$  GeV;
- dois elétrons centrais, um pelo ponto de operação *lhmedium* ou *CutBased* e outro  $p_T > 6, 5$  GeV;
- um elétron pelo ponto de operação *lhmedium* ou *CutBased* e um fóton com  $E_T > 14,5$  GeV.

O EGAM7 para *background* significa a pré-seleção de eventos compatíveis com falsos elétrons, tendo passado por uma cadeia de suporte (monitoramento da eficiência) e tendo um elétron central com  $p_T > 4, 5$  GeV.

Para os eventos simulados de Monte Carlo, foram utilizados os eventos de 2016 para energia de centro de massa de 13 TeV gerados pelo MadGraph (MADGRAPH, 2024): geração dos canais Z + Z ou Z + W e Pythia 8 (PYTHIA, 2024) com colisão próton-próton com o seguinte processo:  $pp \rightarrow WZ + X \rightarrow ll + qq + X$ .

O MadGraph é um framework que visa fornecer todos os elementos necessários para a fenomenologia do Modelo Padrão, e Modelos Além do Modelo Padrão, como o cálculo de seções de choque, a geração de eventos raros e sua correspondência com outros geradores de eventos, além do uso de uma variedade de ferramentas relevantes para manipulação e análise de eventos (MADGRAPH, 2024). O Pythia é um programa para a geração de eventos de colisão física de alta energia, ou seja, para a descrição de colisões em altas energias entre elétrons, prótons, fótons e núcleos pesados (PYTHIA, 2024).

A análise de quadrante foi realizada com eventos simulados de 2021 com energia do centro de massa de 13,6 TeV com geração de eventos do canal  $Z^0 \rightarrow e^+e^-$  feita pelo Pythia 8.

### 9.2 Resultados

Inicialmente, houve o treinamento com os dados reais do primeiro modelo de fusão com 6 variáveis e com o NeuralRinger com metade dos anéis (V12), esse modelo foi chamado de V21, nome dado porque ele é o vigésimo primeiro modelo desenvolvido. Os dados do modelo de shower shape não tinham a possibilidade de serem utilizados para as curvas de eficiência, portanto houve o treinamento de um modelo das 6 variáveis de shower shape chamado de Vss para análise em conjunto, pois no ínicio tinha-se o objetivo de construir as curvas de eficiência antes das tabelas de  $P_D$ . As curvas de eficiência de dados reais e simulados para o regime Boosted foram realizadas para esses dois modelos.

Os trabalhos de (Freund, 2018) e de (Pinto, 2022) comentavam que a variável  $f_3$  apresentava perda de eficiência para partículas com alto  $p_T$  o que afeta diretamente o efeito *Boosted*. Com isso, realizou-se um modelo com apenas 5 variáveis de *shower shape* sem a  $f_3$ , esse modelo foi chamado de Vssoutf3 ou Vss5var.

Antes da finalização da análise, houve um estudo da distância de Wasserstein pelo aluno de Engenharia Elétrica da UFRJ, Lucas Barra de Aguiar Nunes que concluiu que as variáveis  $f_1 e f_3$  não contribuem para a eficiência do *Trigger* em relação às partículas *Boosted* (Nunes, 2022). Neste caso, a  $f_1$  apresenta uma distribuição muito parecida entre jatos e elétrons *Boosted*. Dessa forma, foi finalizada a análise do modelo com 5 variáveis e iniciou-se o treinamento com o modelo de 4 variáveis de *shower shape* chamado de Vssoutfs ou Vss4var.

O novo modelo com quatro variáveis apresentou uma ótima eficiência para os dados *Boosted*, porém um alto falso alarme para dados reais. Com isso, decidiu-se fazer um novo modelo de fusão, chamado V22, com o modelo de quatro variáveis de *shower shape* e o mesmo modelo do *NeuralRinger* com metade dos anéis, V12.

O ambiente utilizado para os treinamentos foi o LPS (Laboratório de Processamento de Sinais) na COPPE-UFRJ. Durante o trabalho, houve uma mudança de contas o que danificou os arquivos de treinamento dos modelos Vss e V21, então houve novamente o treninamento desses modelos, primeiramente com o Vss para depois ele ser introduzido no V21. Esses modelos foram chamados de Vss\_new e V21\_new.

Após todas as curvas de eficiência realizadas, fez-se a tabela de  $P_D$  e depois as análises de quadrante.

### 9.2.1 Tabelas de $P_D$

A tabela de  $P_D$  (Probabilidade de Detecção) mostra os melhores modelos com uma probabilidade de detecção fixa para o valor de referência (*Cutbase*), o índice SP e a taxa de falso alarme para todas as 25 regiões do espaço de fase. Vale ressaltar que o  $P_D$  foi travado em todas as curvas com o valor de referência, então a comparação entre os modelos na tabela, dá-se somente pelo índice SP e pela taxa de falso alarme. Na tabela 5 apresentamos os valores de  $P_D$  para o ponto de operação *tight*. No anexo A, são encontradas as outras tabelas para outros pontos de operação (*medium*, *loose* e very *loose*).

Para a tabela de  $P_D$ , é importante saber a quantidade de dados em cada região para entender melhor as diferentes eficiências das regiões do espaço de fase. A tabela 4 mostra as regiões do espaço de fase com seus respectivos eventos de sinal e *background*. Vale ressaltar que o  $P_D$  foi travado no  $P_D$  de referência para realizar a comparação com todos os modelos, o índice SP e o falso alarme.

Na tabela de  $P_D$  tight (tabela 5), em 9 das 25 regiões, os modelos de fusão apresentam melhores eficiências que os outros em pelo menos 1  $\sigma$  de diferença. Para as outras regiões, eles permanecem na margem de erro.

Tabela 4 - Regiões do espaço de fase e a quantidade de dados de sinal e background.

Região	eventos	$15 < E_T < 20$	$20 < E_T < 30$	$30 < E_T < 40$	$40 < E_T < 50$	$50 < E_T$
$0,00 <  \eta  < 0.80$	sinal	232819	1499273	4188536	4627778	1699541
	background	187639	316581	223869	162421	3769656
$0,\!80 <  \eta  < 1,\!37$	sinal	141000	896615	2539137	2837736	1059922
	background	143657	227709	156992	112229	2560472
$1,37 <  \eta  < 1,54$	sinal	51566	283647	645043	470869	170752
	background	30037	47550	35206	25449	560953
$1,54 <  \eta  < 2,37$	sinal	227345	1132030	2377013	2429079	901075
	background	205792	307253	196711	131668	1318418
$2,37 <  \eta  < 2,50$	sinal	19893	84054	164380	187729	89786
	background	15512	36522	24980	16100	93785

Legenda: As energias transversas  $(E_T)$ estão em GeV. Fonte: Pinto, 2022, p. 84.

Tabela 5 - Tabela de probabilidade de detecção que apresenta os valores de $P_D$ (verde), $SP$ e $P_F$ ( $F_R$ ) (falso alarme ou eficiência de background) para cada
região do espaço de fase com os melhores modelos selecionados pelo $SP_{max}$ para o ponto de operação $tight$

		kinematic region		$15 < E_T[GeV] < 20$			$20 < E_T[GeV] < 30$			$30 < E_T[GeV] < 40$			$40 < E_T[GeV] < 50$			$E_T[\text{GeV}] > 50$	
Det. Region	Method	Туре	$P_D[\%]$	SP[%]	$F_R[\%]$	$P_{D}[\%]$	SP[%]	$F_R[\%]$	$P_{D}[\%]$	SP[%]	$F_R[\%]$	$P_D[\%]$	SP[%]	$F_R[\%]$	$P_D[\%]$	SP[%]	$F_R[\%]$
	Cut-Based (2017)	Reference	97.77	92.60	12.43	98.68	94.79	9.03	99.18	95.94	7.24	99.57	96.17	7.18	99.63	89.40	20.26
	V8	Cross Val.	97.77±0.01	$97.59 \pm 0.10$	$2.59 \pm 0.19$	98.68±0.00	98.49±0.03	$1.69 {\pm} 0.05$	99.17±0.00	$99.10 \pm 0.04$	$0.98 \pm 0.08$	$99.57 \pm 0.01$	99.37±0.04	0.82±0.07	99.63±0.00	$99.55 \pm 0.01$	$0.53 \pm 0.02$
	V12	Cross Val.	97.76±0.01	97.49±0.10	$2.79 \pm 0.19$	98.68±0.00	98.42±0.06	$1.83 {\pm} 0.12$	$99.18 {\pm} 0.00$	$99.05 \pm 0.06$	$1.07 \pm 0.11$	$99.57 \pm 0.01$	99.32±0.04	$0.93 \pm 0.07$	99.63±0.00	$99.54 \pm 0.01$	$0.55 \pm 0.02$
0.00 < - < 0.00	Vss.new	Cross Val.	97.77±0.00	$96.59 \pm 0.07$	$4.57 \pm 0.15$	$98.68 {\pm} 0.00$	97.28±0.06	$4.12 \pm 0.12$	$99.17 {\pm} 0.00$	97.92±0.03	$3.33 \pm 0.05$	$99.57 {\pm} 0.00$	$98.13 {\pm} 0.08$	$3.29 \pm 0.15$	99.63±0.00	$98.99 {\pm} 0.05$	$1.64 {\pm} 0.09$
$0.00 < \eta < 0.80$	V21.new	Cross Val.	97.77±0.01	97.86±0.05	$2.06 \pm 0.10$	98.68±0.00	98.65±0.03	$1.37 \pm 0.05$	$99.17 \pm 0.01$	99.17±0.04	$0.82 \pm 0.07$	$99.57 \pm 0.01$	99.42±0.03	0.73±0.06	99.63±0.00	$99.59 \pm 0.01$	$0.45 \pm 0.02$
	Vss5var	Cross Val.	97.77±0.00	$96.40 \pm 0.11$	$4.95 \pm 0.23$	$98.68 \pm 0.00$	97.11±0.05	$4.44 {\pm} 0.11$	$99.18 {\pm} 0.00$	97.75±0.05	$3.66 {\pm} 0.11$	99.57±0.00	97.94±0.06	$3.69 \pm 0.12$	99.63±0.00	98.88±0.05	$1.85 {\pm} 0.10$
	Vss4var	Cross Val.	97.77±0.00	$95.22 \pm 0.17$	$7.29 \pm 0.34$	$98.68 \pm 0.00$	$96.30 \pm 0.05$	$6.05 {\pm} 0.09$	$99.18 {\pm} 0.00$	$97.29 {\pm} 0.10$	$4.58 \pm 0.19$	$99.57 {\pm} 0.00$	$97.51 \pm 0.05$	$4.54 \pm 0.10$	$99.63 {\pm} 0.00$	$97.70 {\pm} 0.06$	$4.20 \pm 0.11$
	V22	Cross Val.	97.77±0.01	97.83±0.05	$2.10 \pm 0.09$	98.68±0.00	98.66±0.03	$1.37 \pm 0.06$	99.17±0.00	$99.19 {\pm} 0.04$	$0.80 {\pm} 0.08$	$99.57 {\pm} 0.01$	99.43±0.03	0.72±0.07	99.63±0.00	$99.57 \pm 0.01$	$0.48 \pm 0.03$
	Cut-Based (2017)	Reference	97.77	87.48	22.23	98.88	91.28	16.01	99.43	92.95	13.31	99.67	92.82	13.79	99.67	86.26	26.17
	V8	Cross Val.	97.77±0.01	$96.72 \pm 0.10$	$4.32 \pm 0.19$	$98.88 {\pm} 0.00$	$97.86 {\pm} 0.05$	$3.15 {\pm} 0.10$	99.43±0.00	$98.68 {\pm} 0.06$	$2.08 \pm 0.13$	$99.67 {\pm} 0.00$	$99.02 \pm 0.06$	$1.62 \pm 0.11$	$99.67 {\pm} 0.00$	$99.22 \pm 0.01$	$1.24 {\pm} 0.02$
	V12	Cross Val.	97.78±0.01	$96.55 \pm 0.06$	$4.68 \pm 0.12$	$98.88 \pm 0.00$	97.71±0.05	$3.46 {\pm} 0.11$	99.43±0.00	$98.57 \pm 0.06$	$2.29 \pm 0.13$	$99.67 \pm 0.00$	98.93±0.07	$1.82 \pm 0.14$	99.67±0.00	$99.18 {\pm} 0.04$	$1.32 {\pm} 0.08$
0.80 < n < 1.37	Vss.new	Cross Val.	97.77±0.00	$96.10 \pm 0.06$	$5.56 \pm 0.12$	98.88±0.00	$96.99 \pm 0.06$	$4.88 {\pm} 0.11$	99.43±0.00	97.74±0.08	$3.94{\pm}0.16$	99.67±0.00	$98.00 {\pm} 0.08$	$3.67 \pm 0.16$	99.67±0.00	98.67±0.08	$2.32 \pm 0.16$
0.00 \ 1 \ 1.51	V21.new	Cross Val.	97.77±0.01	$97.19 \pm 0.07$	$3.39 \pm 0.13$	$98.88 \pm 0.00$	98.17±0.05	$2.54 \pm 0.09$	99.43±0.01	98.87±0.05	$1.69 {\pm} 0.09$	$99.67 \pm 0.01$	$99.12 \pm 0.07$	$1.42 \pm 0.14$	99.67±0.00	$99.30 \pm 0.02$	$1.06 \pm 0.04$
	Vss5var	Cross Val.	97.77±0.01	95.66±0.08	$6.44 \pm 0.16$	$98.88 \pm 0.00$	96.53±0.07	$5.79 \pm 0.14$	99.43±0.00	97.37±0.09	$4.68 \pm 0.18$	99.67±0.00	$97.61 \pm 0.11$	4.44±0.23	99.67±0.00	98.24±0.07	$3.18 \pm 0.14$
	Vss4var	Cross Val.	97.77±0.01	$94.11 \pm 0.17$	9.49±0.33	98.88±0.00	$95.61 {\pm} 0.08$	$7.60 {\pm} 0.15$	99.43±0.00	$96.76 \pm 0.08$	$5.87 \pm 0.16$	$99.68 {\pm} 0.00$	$97.18 {\pm} 0.11$	$5.29 \pm 0.21$	99.67±0.00	$97.15 {\pm} 0.10$	$5.33 \pm 0.20$
	V22	Cross Val.	97.77±0.01	$97.10 \pm 0.07$	$3.56 \pm 0.15$	$98.88 \pm 0.00$	$98.14 \pm 0.04$	$2.59 \pm 0.08$	99.43±0.00	$98.86 \pm 0.05$	$1.70 {\pm} 0.09$	$99.68 {\pm} 0.01$	$99.13 \pm 0.06$	$1.41 \pm 0.13$	99.67±0.00	$99.30 \pm 0.02$	$1.08 \pm 0.04$
	Cut-Based (2017)	Reference	95.78	78.16	37.67	94.51	84.54	24.86	96.81	88.53	19.37	97.27	89.64	17.68	98.28	49.48	81.97
	V8	Cross Val.	95.77±0.01	93.09±0.28	$9.54 \pm 0.56$	94.49±0.03	95.47±0.15	$3.55 \pm 0.33$	$96.81 \pm 0.05$	$97.19 {\pm} 0.10$	$2.44 {\pm} 0.19$	97.24±0.06	$97.60 {\pm} 0.10$	$2.05 \pm 0.22$	98.28±0.01	98.54±0.07	$1.21 \pm 0.13$
	V12	Cross Val.	95.78±0.01	92.60±0.35	$10.52 {\pm} 0.69$	$94.52 \pm 0.02$	$95.17 \pm 0.17$	$4.18 \pm 0.34$	$96.81 \pm 0.03$	$96.89 {\pm} 0.11$	$3.04 \pm 0.21$	$97.29 \pm 0.08$	$97.43 \pm 0.13$	$2.43 \pm 0.25$	98.28±0.00	$98.46 {\pm} 0.15$	$1.36 {\pm} 0.31$
1 27 < n < 1 54	Vss.new	Cross Val.	95.75±0.08	$71.36 \pm 2.24$	$49.37 \pm 3.76$	$94.50 \pm 0.01$	82.15±1.25	$29.32 \pm 2.30$	$96.81 \pm 0.00$	$84.60 \pm 1.42$	$26.78 \pm 2.63$	$97.26 \pm 0.01$	85.45±1.07	$25.59 \pm 2.00$	98.28±0.00	86.52±2.63	$24.46 \pm 4.86$
$1.57 < \eta < 1.54$	V21.new	Cross Val.	$95.79 \pm 0.01$	$92.81 \pm 0.54$	$10.12{\pm}1.07$	94.53±0.03	$95.29 \pm 0.18$	$3.94 \pm 0.35$	96.77±0.05	$97.03 \pm 0.18$	$2.70 \pm 0.35$	97.24±0.03	$97.48 {\pm} 0.13$	$2.28 \pm 0.24$	98.28±0.00	98.57±0.04	$1.14{\pm}0.08$
	Vss5var	Cross Val.	95.78±0.01	$70.20 \pm 2.12$	$51.32 \pm 3.47$	$94.51 \pm 0.01$	$76.18 \pm 1.26$	$40.16 \pm 2.21$	$96.81 \pm 0.01$	$76.70 \pm 1.87$	$41.03 \pm 3.25$	$97.27 \pm 0.01$	$79.19 \pm 1.80$	$37.01 \pm 3.16$	98.28±0.00	$76.94 \pm 3.55$	$41.68 \pm 6.12$
	Vss4var	Cross Val.	95.78±0.02	63.32±1.08	$62.30{\pm}1.64$	94.59±0.23	68.62±2.66	53.08±4.46	96.81±0.00	72.66±0.74	$47.99 \pm 1.24$	97.27±0.00	$75.66 \pm 1.39$	43.20±2.39	98.41±0.39	69.06±8.40	54.27±11.93
	V22	Cross Val.	95.78±0.01	$92.64 \pm 0.56$	$10.44{\pm}1.10$	94.51±0.05	$95.27 \pm 0.15$	$3.97 \pm 0.28$	96.81±0.03	$97.04 {\pm} 0.18$	$2.73 \pm 0.34$	97.27±0.07	$97.47 \pm 0.15$	$2.34 \pm 0.27$	98.28±0.00	$98.55 {\pm} 0.06$	$1.17 {\pm} 0.12$
	Cut-Based (2017)	Reference	97.40	89.01	19.00	98.23	92.00	14.02	98.97	93.40	12.01	99.21	93.49	12.06	99.32	81.84	33.93
	V8	Cross Val.	97.40±0.01	$96.44 \pm 0.09$	$4.51 {\pm} 0.18$	98.23±0.00	$97.38 {\pm} 0.09$	$3.46 {\pm} 0.19$	98.97±0.01	98.23±0.06	$2.51 \pm 0.12$	$99.22 \pm 0.01$	98.67±0.07	$1.87 \pm 0.13$	99.32±0.00	$98.65 \pm 0.02$	$2.01 \pm 0.05$
	V12	Cross Val.	97.40±0.01	96.43±0.19	$4.54 \pm 0.38$	98.23±0.00	$97.43 \pm 0.16$	$3.36 \pm 0.32$	98.97±0.00	$98.27 \pm 0.11$	$2.43 \pm 0.23$	$99.22 \pm 0.01$	98.67±0.07	$1.87 \pm 0.13$	99.32±0.00	$98.79 \pm 0.09$	$1.74{\pm}0.18$
154 < n < 2.37	Vss.new	Cross Val.	97.40±0.00	$94.30 \pm 0.11$	8.75±0.21	98.23±0.00	95.53±0.08	$7.13 \pm 0.16$	$98.98 \pm 0.00$	$96.69 \pm 0.08$	$5.56 {\pm} 0.16$	$99.22 \pm 0.00$	$97.15 \pm 0.12$	$4.90 \pm 0.23$	99.32±0.00	$97.33 \pm 0.12$	$4.64 \pm 0.24$
1.54 ( 1 ( 2.51	V21.new	Cross Val.	97.40±0.00	96.72±0.06	$3.96 \pm 0.11$	98.23±0.00	$97.61 \pm 0.07$	$3.00 \pm 0.14$	98.97±0.01	98.39±0.05	$2.20 \pm 0.10$	$99.22 \pm 0.01$	98.76±0.08	$1.69 \pm 0.16$	99.32±0.00	98.72±0.03	$1.88 \pm 0.07$
	Vss5var	Cross Val.	97.40±0.00	93.41±0.15	$10.50 {\pm} 0.30$	98.23±0.00	$94.88 \pm 0.09$	$8.41 \pm 0.18$	$98.97 \pm 0.00$	$96.15 \pm 0.13$	$6.63 \pm 0.25$	$99.21 {\pm} 0.00$	$96.78 \pm 0.10$	$5.62 \pm 0.20$	99.32±0.00	96.70±0.26	$5.88 \pm 0.50$
	Vss4var	Cross Val.	97.40±0.00	$92.09 \pm 0.19$	$13.07 {\pm} 0.38$	98.23±0.00	$93.74 \pm 0.13$	$10.65 \pm 0.25$	98.98±0.00	$95.28 \pm 0.12$	8.34±0.23	$99.21 \pm 0.00$	$95.78 \pm 0.09$	$7.58 \pm 0.18$	99.32±0.00	$94.05 \pm 0.22$	$11.07 \pm 0.43$
	V22	Cross Val.	97.40±0.01	96.72±0.08	$3.97 \pm 0.16$	98.23±0.01	97.63±0.07	$2.97 \pm 0.14$	98.98±0.00	98.40±0.04	$2.16 \pm 0.09$	$99.22 \pm 0.01$	98.76±0.08	$1.70 \pm 0.15$	99.32±0.00	98.68±0.03	$1.95 \pm 0.07$
	Cut-Based (2017)	Reference	92.99	70.97	48.06	95.68	74.45	44.10	96.70	77.12	40.24	97.12	77.32	40.22	96.01	52.49	77.49
$2.37 < \eta < 2.50$	V8	Cross Val.	93.02±0.12	$94.08 \pm 0.36$	$4.84 \pm 0.74$	$95.68 \pm 0.06$	$96.01 \pm 0.14$	$3.66 {\pm} 0.27$	96.69±0.13	$97.17 \pm 0.15$	$2.34 \pm 0.34$	96.99±0.24	$97.72 \pm 0.13$	$1.54{\pm}0.18$	$96.00 \pm 0.06$	$97.60 {\pm} 0.06$	$0.79 {\pm} 0.08$
	V12	Cross Val.	92.99±0.13	$93.91 \pm 0.41$	$5.16 \pm 0.83$	95.67±0.04	95.89±0.14	$3.89 \pm 0.27$	96.68±0.12	$97.09 \pm 0.14$	$2.49 \pm 0.32$	97.10±0.13	97.73±0.14	$1.64 \pm 0.22$	96.00±0.06	97.58±0.05	0.83±0.09
	Vss.new	Cross Val.	93.06±0.10	$89.80 {\pm} 0.68$	$13.40{\pm}1.29$	95.68±0.03	$91.58 \pm 0.37$	$12.42 \pm 0.72$	$96.70 \pm 0.01$	$93.10 {\pm} 0.39$	$10.43 {\pm} 0.76$	97.13±0.02	$93.45 \pm 0.63$	$10.15 {\pm} 1.22$	$96.01 \pm 0.01$	$94.13 \pm 0.37$	7.73±0.73
	V21.new	Cross Val.	92.96±0.15	93.92±0.35	$5.11 {\pm} 0.66$	95.66±0.05	$95.98 \pm 0.13$	$3.71 \pm 0.25$	96.68±0.13	$97.12 \pm 0.13$	$2.43 \pm 0.27$	97.12±0.13	$97.77 {\pm} 0.10$	$1.57 {\pm} 0.20$	96.03±0.14	$97.59 {\pm} 0.10$	$0.83 {\pm} 0.10$
	Vss5var	Cross Val.	92.99±0.04	88.71±0.43	$15.47 {\pm} 0.85$	95.68±0.02	89.95±0.29	$15.61 \pm 0.56$	96.70±0.02	90.81±1.30	$14.88 {\pm} 2.49$	97.12±0.04	$91.78 \pm 0.74$	$13.40 \pm 1.44$	96.01±0.01	$91.68 \pm 0.52$	$12.54 \pm 1.02$
	Vss4var	Cross Val.	92.98±0.05	85.79±0.83	$21.11 {\pm} 1.60$	95.67±0.01	87.36±0.79	$20.57 \pm 1.50$	96.70±0.02	88.07±0.77	$20.15 \pm 1.47$	97.12±0.03	88.58±0.70	$19.56 {\pm} 1.34$	96.00±0.00	88.22±0.99	$19.24 {\pm} 1.90$
	V22	Cross Val.	92.98±0.07	93.79±0.35	$5.39 \pm 0.69$	95.70±0.04	$95.98 \pm 0.11$	$3.74 \pm 0.22$	96.73±0.17	$97.14 \pm 0.21$	$2.44 \pm 0.33$	97.11±0.17	$97.75 \pm 0.14$	$1.61 \pm 0.21$	96.01±0.05	$97.59 \pm 0.05$	$0.82 {\pm} 0.10$

Fonte: O autor, 2024.

### 9.2.2 Curvas de eficiência (*Turn ons*)

As curvas de eficiência medem a eficiência ou o falso alarme de cada um dos modelos com base em uma variável, essas variáveis são:  $E_T$ ,  $p_T$ ,  $\eta$ ,  $\mu$  (empilhamento) e, no caso *Boosted*,  $\Delta R$ . As cadeias são:

- e24\_lhtight\_ivarloose;
- e26\_lhtight\_ivarloose;
- e60\_lhmedium;
- e140\_lhloose.

As assinaturas das cadeias acima estão explicadas na seção 2.3.5. Nesta subseção, será apresentada somente a cadeia e24\_lhtight\_ivarloose, ou seja, um elétron com energia transversa acima de 24 GeV (21 GeV) utilizando a estratégia de máxima verossimilhança com a exigência de candidatos isolados no ponto de operação *tight*. No anexo B podem ser encontradas as outras cadeias, assim como as outras variáveis.

As legendas dos gráficos apresentam em ordem: o NeuralRinger com 100 anéis (V8, triângulo azul), o NeuralRinger com 50 anéis (V12, triângulo verde invertido), o modelo de fusão com 6 variáveis de shower shape (V21, "x"amarelo), o modelo do shower shape com 6 variáveis (Vss, estrela vermelha), o modelo do shower shape com 5 variáveis (VssOutf3, círculo rosa), o modelo do shower shape com 4 variáveis (VssOutf3, quadrado preto), o modelo de fusão com 4 variáveis de shower shape (V22, bola azul), o novo modelo de shower shape com 6 variáveis (VssNew, cruz vermelha) e o novo modelo de fusão com 6 variáveis (VssNew, cruz vermelha) e o novo modelo de fusão com 6 variáveis de shower shape (V21New, cruz turquesa). A figura 43 apresenta a descrição dos modelos. A figura 44 apresenta a legenda dos modelos presentes no gráfico.

Os gráficos da figura 45 mostram as curvas de eficiência de  $P_D$  para a distribuição de  $E_T$  para as quatro etapas do *Trigger* para eventos reais. Essa figura exemplifica o que a tabela de  $P_D$  demonstra, a probabilidade de detecção perto do valor de referência já que eles são fixados nesse resultado, portanto não serão expostos outros resultados referentes ao  $P_D$  em dados reais de treinamento. Pode-se dizer que esse gráfico traz uma parte especifica da tabela de  $P_D$  onde houve o travamento do  $P_D$  com a referência (*Cutbase*).

As curvas de falso alarme para a distribuição de  $E_T$  para as três etapas do *Trigger* para eventos reais estão apresentadas na figura 46. Vale ressaltar que quanto menor a taxa de falso alarme, melhor para o modelo, pois ela indica a taxa de jatos que foram classificados como elétrons. Nos gráficos, percebe-se a grande diferença entre os modelos compostos somente por *shower shape* (Vss, Vssoutf3, Vssoutfs e VssNew) com altos índices de *background* e os modelos que apresentam anéis (V8, V12, V21, V22 e V21New) com os melhores resultados. Figura 43 - Descrição dos modelos

```
V8 – 100 anéis (Δ)

V12 – 50 anéis (∇)

V21 – fusão (x)

(50 anéis + SS_6var)

Vss – Modelo de Shower Shape (☆) (SS)

Vssoutf3 – Modelo de Shower Shape sem f3 (○)

Vssoutfs – Modelo de Shower Shape sem f1 e f3 (■)

V22 – fusão (●)

(50 anéis + SS_4var)

VssNew – Novo Modelo de Shower Shape (SS) (+)

V21new – fusão nova (+)

(50 anéis + SS_6var)
```

Legenda: Legenda com a descrição dos modelos dos gráficos. Fonte: O autor, 2024.

Figura 44 - Legenda dos modelos presentes no gráfico



Legenda: Legenda ampliada presente nos gráficos para facilitar a visualização. Após o número das versões como V8, ignorar o resto, pois em cada gráfico aparecerá diferente. Fonte: O autor, 2024.

A figura 47 mostra as curvas de falso alarme para a distribuição de  $p_T$  para as quatro etapas do *Trigger* para eventos reais. Com o aumento do momento transverso, a taxa de *background* aumenta, principalmente para modelos que não possuem anéis (Vss, Vssoutf3, Vssoutfs e VssNew), porém os modelos de fusão (V21, V22 e V21New), as taxas permanecem abaixo dos modelos do *NeuralRinger* ou com eficiências equivalentes para altos momentos transversos.

Para eventos de simulação de Monte Carlo (eventos *Boosted*) temos como principais variáveis o  $E_T$ ,  $p_T \in \Delta R$ . Esses resultados juntamente com o falso alarme dos gráficos anteriores representam as variáveis em que os modelos devem apresentar altas eficiências, pois o falso alarme deve ser baixo enquando a probabilidade de detecção nos dados de validação deve ser alta para que o modelo traga melhores resultados gerais. Os



Figura 45 - Eficiência de identificação de elétrons (probabilidade de detecção) relativa a  $E_T$  dos eventos reais (treinados)

Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT Fonte: O autor, 2024.

gráficos da figura 48 mostram as curvas de eficiência de  $P_D$  para a distribuição de  $E_T$  para as quatro etapas do *Trigger* para eventos simulados. Nesses gráficos, não há diferenças significativas entre os modelos, mas a partir de 100 GeV, há uma queda de eficiência dos modelos de 100 anéis (V8) e a nova fusão com 6 variáveis (V21New).

As curvas de eficiência de  $P_D$  para a distribuição de  $p_T$  para as quatro etapas do Trigger para eventos simulados estão apresentadas na figura 49. Nesses gráficos, o modelo com 4 variáveis de shower shape (Vssoutfs) apresenta melhores eficiências, porém nos gráficos anteriores de falso alarme para eventos reais, esse modelo apresenta eficiências de background altas. A primeira fusão (V21) e a fusão com 4 variáveis (V22), apresentam eficiências muito próximas do NeuralRinger com metade dos anéis (V12). O NeuralRinger com 100 anéis (V8) apresenta as piores eficiências nas avaliações de dados simulados.

Os gráficos da figura 50 mostram as curvas de eficiência de  $P_D$  para a distribuição de  $\Delta R$  para as quatro etapas do *Trigger* para eventos simulados. Para esses gráficos, os resultados apresentam eficiências bem próximas a partir do quarto *bin*, no primeiro



Figura 46 - Eficiência de identificação de jatos (falso alarme) como elétrons relativa a  $E_T$ 

Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo. Fonte: O autor, 2024.

*bin*, abaixo das eficiências do modelo de 4 variáveis de *shower shape*, o primeiro modelo de fusão (V21) e o *NeuralRinger* com metade dos anéis (V12) apresentam melhores resultados, nos outros dois *bins*, os dois modelos de fusão (V21 e V22) e o *NeuralRinger* com metade dos anéis (V12) estão com melhores eficiências.

Vale ressaltar a perda de eficiência das etapas Fast para HLT na região em torno de 0,2 de  $\Delta R$ . Essa diferença pode ter uma explicação devido à forma que é realizada a extração de informação, ou seja, há perda de informação ao se passar para etapa precisa onde há a calibração de energia, em que possivelmente a janela de reconstrução não consegue diferenciar essa região por não ter uma granularidade adequada.

#### 9.2.3 Análise de quadrante

A análise de quadrante tem como objetivo analisar o acordo e o desacordo entre dois modelos dividindo em 4 casos distintos. Os casos são: ambos aceitam o elé-



Figura 47 - Eficiência de identificação de jatos (falso alarme) como elétrons relativa a  $p_T$ 

Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.

tron, somente o primeiro aceita, somente o segundo aceita e ambos rejeitam o elétron. As variáveis utilizadas para o quadrante são as variáveis *offline* do *shower shape* para identificação de elétrons.

Devido às suas distribuições, as variáveis que apresentam maior poder de discriminação são o  $E_{ratio}$  (figura 29) e  $R_{had}$ . A variável  $R_{had}$  não está disponível na etapa FastCalo, a sua distribuição está apresentada na figura 51.

Os gráficos das figuras 52a e 52b mostram que os modelos com 100 anéis e o outro com 6 variáveis físicas apresentam um grande desacordo entre si. Percebe-se que o *NeuralRinger* apresenta melhores decisões nas regiões nobres dos gráficos que são 1.0 para  $E_{ratio}$  e 0.0 para  $R_{had}$ , porém há também contribuições do modelo de *shower shape* nas regiões nobres. Isso indica algo que o *NeuralRinger* não é sensível e pode ser aproveitado ao realizar a fusão com o modelo das variáveis de *shower shape*.

Os gráficos das figuras 53a, 53b e 53c mostram um menor desacordo entre o v8 (100 anéis) e os modelos de fusão. O gráfico da figura 53a apresenta uma queda de desacordo na região nobre, o que demonstra um bom aproveitamento do modelo. O



Figura 48 - Eficiência de identificação de elétrons (probabilidade de detecção) relativa a  $E_T$  eventos simulados (elétrons *Boosted*)

Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.

gráfico da figura 53b apresenta uma queda um pouco menor que a anterior, porém um alto valor absoluto de desacordo. O gráfico da figura 53c já demonstra uma elevação de desacordo na região nobre, o que demonstra que o modelo vai em uma direção oposta.

Os gráficos das figuras 54a, 54b e 54c mostram que o *NeuralRinger* fusionado tem maior poder de decisão que os modelos do *shower shape* devido ao grande desacordo da região nobre.

Figura 49 - Eficiência de identificação de elétrons (probabilidade de detecção) relativa a  $p_T$  eventos simulados (elétrons *Boosted*)



Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.



Figura 50 - Eficiência de identificação de elétrons (probabilidade de detecção) relativa a  $\Delta R$  eventos simulados (elétrons Boosted)

Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.

Figura 51 - Distribuição  $R_{had}$ 



Legenda: Sinal (preto) e *background* (vermelho) da distribuição  $R_{had}$ . Fonte: Araújo, 2019, p. 29.





Figura 52 - Quadrante dos modelos v8 (100 anéis) contra vssnew (6 variáveis)

Legenda: (a) Quadrante  $E_{ratio}$ , (b) Quadrante  $R_{had}$ . Fonte: O autor, 2024.



Figura 53 - Quadrante do modelo v<br/>8 (100 anéis) contra os modelos de fusão





Legenda: (a) v8xv21, (b) v8xv21new, (c) v8xv22. Fonte: O autor, 2024.



Figura 54 - Quadrante do modelo de fusão contra os seus respectivos modelos de shower shape

Legenda: (a) v21xvss, (b) v21newxvssnew, (c) v22xvssoutfs. Fonte: O autor, 2024.

## CONCLUSÃO E TRABALHOS FUTUROS

### Conclusão

A Física de Altas Energias, por apresentar altas taxas de eventos e uso de muitas variáveis, é um excelente cenário para o uso da fusão de informação, uma vez que apresenta um ambiente de extremo interesse para a utilização dessa técnica, porém limitada devido à necessidade de baixa latência. Há poucos trabalhos que relacionam Altas Energias com fusão de informação, neles, percebe-se uma relevância maior quando empregada na utilização de informação proveniente de detectores distintos como o detectores de traços, calorímetros e câmara de múons.

Como foi apresentado, os modelos NeuralRinger apresentam melhores resultados quando comparados a modelos que não utilizam anéis (shower shape), mas com a análise de quadrante, percebe-se que há certas características que o modelo com apenas variáveis tradicionais do shower shape consegue perceber e o NeuralRinger não. Dessa forma, a estratégia de fusão de informação demonstrou ser uma opção para o desenvolvimento de um novo filtro online para o Trigger do HLT do ATLAS como mostram os resultados referentes à tabela de  $P_D$  em que a fusão possui melhores taxas de falso alarme que todos os outros modelos.

No caso *Boosted*, as curvas de eficiência demonstram que a primeira fusão (V21) e a fusão com 4 variáveis (V22) apresentam resultados similares à melhor estratégia atual, o *NeuralRinger* com metade dos anéis (V12).

Apesar dos bons resultados, com a análise de quadrante, percebe-se que nos modelos de fusão, a parte do *NeuralRinger* apresenta maior decisão que os modelos de *shower shape*. Com isso, os modelos de fusão atuais podem apresentar melhores eficiências ao se realizar uma tendência para o modelo do *NeuralRinger*, o que para uma arquitetura distribuída é de total relevância no seu desempenho.

### Trabalhos futuros

Este trabalho segue em desenvolvimento, é necessário investigar e desenvolver modelos de fusão com um viés para o modelo do *NeuralRinger*, assim como a realização de treinamentos e avaliações com os dados da *Run 3* para ver como se comporta o modelo na nova faixa de energia. Com aumento da energia e consequentemente da luminosidade, é de extrema importância o desenvolvimento de técnicas mais avançadas para o *trigger*, pois no futuro, como por exemplo no FCC (*Future Circular Colider*) (European [...], 2024a), será mais difícil selecionar eventos de interesse devido principalmente ao aumento do empilhamento. O FCC tem como objetivo aumentar a energia e a intensidade das colisões das partículas de uma ordem de 100 TeV e realizar uma busca por uma nova física.

Estamos interessados em aplicar as mesmas técnicas (*shower shape* e fusão de informação) no simulador Lorenzetti (Araújo *et al.*, 2023), que possui caraterísticas próximas às do detector ATLAS. No Doutorado, darei continuidade na exploração da fusão de informação aplicada à Física de Altas Energias considerando eventos usuais e boosted.
## REFERÊNCIAS

ACHENBACH, R. et al. The atlas level-1 calorimeter trigger. JINST 3, [s.l.]. 2008. Disponível em: https://cds.cern.ch/record/1080560?ln=pt. Acesso em: 29 dez. 2023.

AHMAD, A. et al. The silicon microstrip sensors of the atlas semiconductor tracker. *Nucl. Instrum. Methods Phys. Res.*, [s.l.]. 2007. Disponível em: https://cds.cern.ch/record/1019885. Acesso em: 29 dez. 2023.

ALISON, J. et al. Description and performance of the electron likelihood tool at atlas using 2012 lhc data. [s.l.]. 2013. Disponível em: https://cds.cern.ch/record/1537410. Acesso em: 29 dez. 2023.

ANASTOPOULOS, C. et al. Supporting document on electron identification and efficiency measurements using the 2015 LHC proton-proton collision data. [s.l.]. 2016. Disponível em: https://cds.cern.ch/record/2125283. Acesso em: 29 dez. 2023.

ANJOS, A. R. Sistema online de filtragem em um ambiente com alta taxa de eventos. 2006. Tese (Doutorado em Engenharia Elétrica) — Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2006.

ANNIHILATION. 2011. Disponível em: https://en.wikipedia.org/wiki/Annihilation. Acesso em: 12 mar. 2024.

ARAúJO, M. V. Filtragem online baseada em calorimetria de altas energias e com alta taxa de eventos. 2019. Dissertação (Mestrado em Ciências em Engenharia Elétrica)
— Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2019.

ARAúJO, M. V. et al. Lorenzetti Showers - A general-purpose framework for supporting signal reconstruction and triggering with calorimeters. [s.l.]. 2023. Disponível em: https://www.sciencedirect.com/science/article/abs/pii/S0010465523000164. Acesso em: 29 dez. 2023.

ASSIS, V. A. *Procura do bóson Z' utilizando dados da plataforma ATLAS Open Data.* 2021. Monografia (Graduação em Física) — Instituto de Física Armando Dias Tavares, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2021.

ATLAS, O. D. *Glossary, Detector layout.* [Genève]: European Organization for Nuclear Research, 2018. Disponível em: http://opendata.atlas.cern/books/current/get-started/ \\_book/GLOSSARY.html. Acesso em: 19 jun. 2023.

ATLAS COLLABORATION. Atlas liquid-argon calorimeter : Technical design report. *Technical design report*, [s.l.]. 1996. Disponível em: https://cds.cern.ch/record/331061? ln=pt. Acesso em: 29 dez. 2023.

ATLAS COLLABORATION. Atlas inner detector : Technical design report, 1. *Technical design report. ATLAS*, [s.l.]. 1997. Disponível em: https://cds.cern.ch/record/331063. Acesso em: 29 dez. 2023.

ATLAS COLLABORATION. The atlas experiment at the cern large hadron collider. JINST, [s.l.], v.3. 2008. Disponível em: https://iopscience.iop.org/article/10.1088/ 1748-0221/3/08/S08003. Acesso em: 29 dez. 2023.

ATLAS COLLABORATION. The atlas level-1 trigger system. J. Phys.: Conf. Ser., [s.l.]. 2012a. Disponível em: https://cds.cern.ch/record/1456546. Acesso em: 29 dez. 2023.

ATLAS COLLABORATION. Performance of the atlas trigger system in 2010. *Eur.Phys.J.C*, [s.l.]. 2012b. Disponível em: https://arxiv.org/abs/1110.1530. Acesso em: 29 dez. 2023.

ATLAS COLLABORATION. Electron efficiency measurements with the atlas detector using 2012 lhc proton-proton collision data. *Eur. Phys. J. C*, [s.l.]. 2016a. Disponível em: https://cds.cern.ch/record/2237544. Acesso em: 29 dez. 2023.

ATLAS COLLABORATION. Electron efficiency measurements with the atlas detector using the 2015 lhc proton-proton collision data. *51st Rencontres de Moriond on QCD and High Energy Interactions*, [s.l.]. 2016b. Disponível em: https://cds.cern.ch/record/2157687. Acesso em: 29 dez. 2023.

ATLAS COLLABORATION. Luminosity determination in pp collisions at  $\sqrt{s} = 8$  tev using the atlas detector at the lhc. [s.l.]. 2016c. Disponível em: https: //cds.cern.ch/record/2208146. Acesso em: 29 dez. 2023.

ATLAS COLLABORATION. Electron and photon reconstruction and performance in atlas using a dynamical, topological cell clustering-based approach. [s.l.]. 2017a. Disponível em: https://cds.cern.ch/record/2298955. Acesso em: 29 dez. 2023.

ATLAS COLLABORATION. Topological cell clustering in the atlas calorimeters and its performance in lhc run 1. *Eur.Phys.J.C*, [s.l.]. 2017b. Disponível em: https://arxiv.org/abs/1603.02934. Acesso em: 29 dez. 2023.

ATLAS COLLABORATION. Atlas tile calorimeter calibration and monitoring systems. [s.l.]. 2018. Disponível em: https://cds.cern.ch/record/2266688/files/epjconf\_animma2018\_01003.pdf. Acesso em: 29 dez. 2023.

ATLAS COLLABORATION. Performance of electron and photon triggers in atlas during lhc run 2. *Eur. Phys. J. C*, [s.l.]. 2020. Disponível em: https://arxiv.org/abs/1909.00761. Acesso em: 29 dez. 2023.

ATLAS COLLABORATION. *Pseudo-rapidity*. 2024a. Disponível em: https://atlas.cern/glossary/pseudo-rapidity. Acesso em: 19 jun. 2023.

ATLAS COLLABORATION. The atlas trigger system for lhc run 3 and trigger performance in 2022. *arXiv:2401.06630 [hep-ex]*, [s.l.]. 2024b. Disponível em: https://atlas.web.cern.ch/Atlas/GROUPS/PHYSICS/PAPERS/TRIG-2022-01/. Acesso em: 29 dez. 2023.

ATLAS TRT COLLABORATION et al. The atlas trt barrel detector. *Journal of Instrumentation*, [s.l.]. 2008. Disponível em: https://iopscience.iop.org/article/10.1088/1748-0221/3/02/P02014. Acesso em: 29 dez. 2023.

BALABRAM FILHO, L. E. Fator de qualidade para um calorímetro de altas energias operando com alta taxa de eventos. 2014. Dissertação (Mestrado em Ciências em Engenharia Elétrica) — Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa em Engenharia, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2014.

BELAROUSSI, R.; PREVOST, L.; MILGRAM, M. Algorithms fusion for face localization. *Journal of Advances in Information Fusion*, [s.l.]. 2006. Disponível em: https://isif.org/journal/1/1. Acesso em: 29 dez. 2023.

BILENKY, S.; HOŠEK, J. Glashow-weinberg-salam theory of electroweak interactions and the neutral currents. *Physics Reports*, [s.l.]. v. 90, 1982. Disponível em: https://www.sciencedirect.com/science/article/abs/pii/0370157382900163. Acesso em: 29 dez. 2023.

BRENDLINGER, K. *Physics with Electrons in the ATLAS Detector.* 2016. Tese (Degree of Doctor of Philosophy) — The University of Pennsylvania, 2016.

CAMPOS, G. M. S. Busca por matéria escura no CMS/LHC: um estudo de implementação de métodos de Aprendizado de Máquina e aplicação de fatores de correção para jatos de quark bottom. 2023. Dissertação (Mestrado em Física) — Instituto de Física Armando Dias Tavares, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2023.

CARLINO, N. G. et al. Electron trigger efficiency for vv semi-leptonic analysis. *DBL* meeting, [s.l.]. 2018. Disponível em: https://indico.cern.ch/event/773631/contributions/ 3302340/attachments/1787867/2911550/DBLAnalysis\_TriggerEff\_DBLMeeting\_ 30jan19.pdf. Acesso em: 29 dez. 2023.

CASTANEDO, F. A review of data fusion techniques. *The ScientificWorld Journal*, [s.l.]. v. 2013, 2013. Disponível em: http://dx.doi.org/10.1155/2013/704504. Acesso em: 29 dez. 2023.

CHEN, F. C.; JAHANSHAHI, M. R. Nb-cnn: Deep learning-based crack detection using convolutional neural network and naïve bayes data fusion. *Transactions on Industrial Electronics*, [s.l.]. v. 65, n. 5, p. 4392–4400, 2018. Disponível em: https://ieeexplore-ieee-org.ez83.periodicos.capes.gov.br/stamp/stamp.jsp?tp=&arnumber=8074762.

CHENG-HUNGCHEN; NAIDU, D. S. Fusion of hard and softcontrol strategies for the robotic hand. New york: Wiley, 2017. Disponível em: https://onlinelibrary-wiley.ez83. periodicos.capes.gov.br/doi/book/10.1002/9781119273622.

CHIEDDE, N. Implementation of embedded artificial intelligence algorithms in the readout system of the ATLAS liquid argon calorimeter. 2023. Tese (Doutorado em Física e Ciências da Matéria) — Aix-Marseille Université, Marseille, 2023.

CMS COLLABORATION. *The CMS experiment at the CERN LHC*. 2008. Disponível em: https://iopscience.iop.org/article/10.1088/1748-0221/3/08/S08004. Acesso em: 29 dez. 2023.

CMS COLLABORATION. Search for a heavy vector resonance decaying to a z boson and a higgs boson in proton-proton collisions at s = 13 tev. The European Physical Jornal C, [s.l.]. v. 81, 2021. Disponível em: https://doi.org/10.1140/epjc/s10052-021-09348-6. Acesso em: 29 dez. 2023.

DASARATHY, B. V. Sensor fusion potential exploitation-innovative architectures and illustrative applications. *IEEE*, [s.l.]. v. 85, 1997. Disponível em: https://ieeexplore-ieee-org.ez83.periodicos.capes.gov.br/stamp/stamp.jsp?tp=&arnumber=554206. Acesso em: 29 dez. 2023.

DOU, W. et al. Distributed fusion algorithm for passive localization of multiple transient emitters. *Journal of Advances in Information Fusion*, [s.l.]. 2018. Disponível em: https://isif.org/journal/13/1. Acesso em: 29 dez. 2023.

ENGLERT, F.; BROUT, R. Broken symmetry and the mass of gauge vector mesons. *Phys. Rev. Lett.*, [s.l.]. v. 13, 1964. Disponível em: https://journals.aps.org/prl/abstract/10.1103/PhysRevLett.13.321. Acesso em: 29 dez. 2023.

EUROPEAN ORGANIZATION FOR NUCLEAR RESEARCH. Computer Generated image of the ATLAS calorimeter. European Organization for Nuclear Research, 2008a. Disponível em: https://cds.cern.ch/record/1095927. Acesso em: 1 set. 2023.

EUROPEAN ORGANIZATION FOR NUCLEAR RESEARCH. Computer generated image of the ATLAS inner detector. European Organization for Nuclear Research, 2008b. Disponível em: https://cds.cern.ch/record/1095926. Acesso em: 1 set. 2023.

EUROPEAN ORGANIZATION FOR NUCLEAR RESEARCH. Computer generated image of the ATLAS Muons subsystem. European Organization for Nuclear Research, 2008c. Disponível em: https://cds.cern.ch/record/1095929. Acesso em: 1 set. 2023.

EUROPEAN ORGANIZATION FOR NUCLEAR RESEARCH. LHCb experiment discovers a new pentaquark. 2019. Disponível em: https://home.cern/news/news/physics/lhcb-experiment-discovers-new-pentaquark. Acesso em: 19 jan. 2024.

EUROPEAN ORGANIZATION FOR NUCLEAR RESEARCH. *CERN's accelerator complex.* 2022. Disponível em: https://home.cern/science/accelerators/accelerator-complex. Acesso em: 1 set. 2023.

EUROPEAN ORGANIZATION FOR NUCLEAR RESEARCH. *ALICE Collaboration*. 2023a. Disponível em: https://alice-collaboration.web.cern.ch. Acesso em: 19 jun. 2023a.

EUROPEAN ORGANIZATION FOR NUCLEAR RESEARCH. *ATLAS.* 2023b. Disponível em: https://home.cern/science/experiments/atlas. Acesso em: 19 jun. 2023b.

EUROPEAN ORGANIZATION FOR NUCLEAR RESEARCH. *CERN*. European Organization for Nuclear Research, 2023c. Disponível em: https://www.home.cern/. Acesso em: 04 set. 2023c.

EUROPEAN ORGANIZATION FOR NUCLEAR RESEARCH. CMS. 2023d. Disponível em: https://home.cern/science/experiments/cms. Acesso em: 19 jun. 2023d.

EUROPEAN ORGANIZATION FOR NUCLEAR RESEARCH. *The Large Hadron Collider*. 2023e. Disponível em: https://home.cern/science/accelerators/large-hadron-collider. Acesso em: 19 jun. 2023e.

EUROPEAN ORGANIZATION FOR NUCLEAR RESEARCH. *LHC Run 3.* 2023f. Disponível em: https://home.cern/press/2022/run-3. Acesso em: 04 set. 2023f.

EUROPEAN ORGANIZATION FOR NUCLEAR RESEARCH. *LHCb*. 2023g. Disponível em: https://home.cern/science/experiments/lhcb. Acesso em: 19 jun. 2023g.

EUROPEAN ORGANIZATION FOR NUCLEAR RESEARCH. *The Future Circular Colider*. 2024a. Disponível em: https://home.cern/science/accelerators/future-circular-collider. Acesso em: 02 jan. 2024a.

EUROPEAN ORGANIZATION FOR NUCLEAR RESEARCH. CERN press release: CERN experiments observe particle consistent with long-sought higgs boson. 2024b. Disponível em: https://cds.cern.ch/journal/CERNBulletin/2012/28/News%20Articles/ 1459454?ln=en. Acesso em: 22 jan. 2024b.

FAWCETT, T. An introduction to ROC analysis. [s.l.]. 2006. Disponível em: https://people.inf.elte.hu/kiss/11dwhdm/roc.pdf. Acesso em: 29 dez. 2023.

FERREIRA, I. S. Aprendizado profundo para filtragem online numa região de baixa resolução de um calorímetro finamente segmentado. 2022. Dissertação (Mestrado em Ciências em Engenharia Elétrica) — Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa em Engenharia, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2022.

FREIRE, A. *Introdução à Física de Partículas*. São Paulo: Livraria da Física, 2010. (Coleção CBPF - Tópicos de Física). ISBN 9788578610661.

FREUND, W. S. Identificação de Elétrons Baseada em um Calorímetro de Altas Energias Finamente Segmentado. 2018. Tese (Doutorado em Engenharia Elétrica) — Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa em Engenharia, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2018.

GAILLARD, M. K.; GRANNIS, P. D.; SCIULLI, F. J. The standard model of particle physics. *Reviews of Modern Physics*, [s.l.]. v. 71, 1998. Disponível em: https://arxiv.org/pdf/hep-ph/9812285.pdf. Acesso em: 29 dez. 2023.

GAMA, R. G. Filtragem Online Baseada na Fusão de Informação de Detectores Finamente Segmentados. 2017. Tese (Doutorado em Engenharia Elétrica) — Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa em Engenharia, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2017.

GASPAR, P. Modelos neurais para a correção de estimativas de eventos raros em um experimento de altas enerias. 2016. Dissertação (Mestrado em Ciências em Engenharia Elétrica) — Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa em Engenharia, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2016.

GLASHOW, S. L.; ILIOPOULOS, J.; MAIANI, L. Weak interactions with lepton-hadron symmetry. *Phys. Rev. D*, [s.l.]. v. 2, 1970. Disponível em: https: //journals.aps.org/prd/abstract/10.1103/PhysRevD.2.1285. Acesso em: 29 dez. 2023.

GLASHOW, S. L.; WEINBERG, S. Natural conservation laws for neutral currents. *Phys. Rev.*, [s.l.]. D 15,, 1977. Disponível em: https://journals.aps.org/prd/abstract/10.1103/ PhysRevD.15.1958. Acesso em: 29 dez. 2023.

GRIFFITHS, D. Introduction to elementary particles. 2nd rev. version. New York, NY: Wiley, 2008. (Physics textbook).

GURALNIK, G. S.; HAGEN, C. R.; KIBBLE, T. W. B. Global conservation laws and massless particles. *Phys. Rev. Lett.*, [s.l.]. v. 13, 1964. Disponível em: https://journals.aps.org/prl/abstract/10.1103/PhysRevLett.13.585. Acesso em: 29 dez. 2023.

HANAGAKI, K. et al. Experimental Techniques in Modern High-Energy Physics A Beginner's Guide. [s. l.]: Springer, 2022. ISBN 978-4-431-56931-2. Disponível em: https://doi.org/10.1007/978-4-431-56931-2.

HAYKIN, S. *Redes Neurais: princípios e práticas.* 2 ed. Porto Alegre: Bookman, 2001. ISBN 9788573077186.

HEM, A. G.; BREKKE, E. F. Variations of joint integrated data association with radar and target-provided measurements. *Journal of Advances in Information Fusion*, [s.l.]. 2022. Disponível em: https://confcats\_isif.s3.amazonaws.com/web-files/journals/entries/Pages%20from%20JAIF-v17-i2-3\_3.pdf. Acesso em: 29 dez. 2023.

HERWIG, C. et al. Shedding light on the MiniBoone Excess with Searches at the LHC. [s.l.]. 2023. Disponível em: https://arxiv.org/abs/2310.13042. Acesso em: 29 dez. 2023.

HIGGS, P. W. Spontaneous symmetry breakdown without massless bosons. *Phys. Rev.*, [s.l.]. v. 145, 1966. Disponível em: https://journals.aps.org/pr/abstract/10.1103/ PhysRev.145.1156. Acesso em: 29 dez. 2023.

HIPERCARGA fraca. 2023. Disponível em: https://pt.wikipedia.org/wiki/Hipercarga\_fraca. Acesso em: 05 fev. 2024.

KAJITA, T. *Takaaki Kajita Nobel Lecture*. 2015. Disponível em: https://www.nobelprize. org/prizes/physics/2015/kajita/lecture/. Acesso em: 05 fev. 2024.

KAJITA, T. et al. Establishing atmospheric neutrino oscillations with super-kamiokande. *Nuclear Physics B*, [s.l.]. 2016. Disponível em: https://doi.org/10.1016/j.nuclphysb.2016. 04.017. Acesso em: 29 dez. 2023.

KINGMA, D. P.; BA, J. L. Adam: a method for stochastic optimization. *ICLR*, [s.l.]. 2015. Disponível em: https://arxiv.org/pdf/1412.6980.pdf.

KRUSHNASAMY, V. S.; RASHINKAR, P. An overview of data fusion techniques. In: INTERNATIONAL CONFERENCE ON INNOVATIVE MECHANISMS FOR INDUSTRY APPLICATIONS 2017. [Proceedings ...], m[s.l.]. 2017. Acesso em: 29 dez. 2023.

LIGGINS, M. E.; HALL, D. L.; LLINAS., J. Handbook of Multisensor Data Fusion: Theory and Practice. 2nd. ed. [s.l.]: CRC Press, 2017. (Electrical Engineering Applied Signal Processing Series 22). ISBN 978-1-4200-5308-1.

LIU, J. et al. Identification of potential parkinson's disease drugs based on multi-source data fusion and convolutional neural network. *Molecules*, [s.l.]. v. 27, p. 4780, 2022. Disponível em: https://www.mdpi.com/1420-3049/27/15/4780. Acesso em: 29 dez. 2023.

LIU, L. et al. Monitoring of volcanic ash cloud from heterogeneous data using feature fusion and convolutional neural networks-long short-term memory. *Neural Computing and Applications*, [s.l.]. v. 33, p. 667–679, 2021. Disponível em: https://link-springer-com.ez83.periodicos.capes.gov.br/article/10.1007/s00521-020-05050-y. Acesso em: 29 dez. 2023.

MADGRAPH. Disponível em: http://madgraph.phys.ucl.ac.be/. Acesso em: 12 mar. 2024.

MARTIN, T. W.; CHANG, K. A distributed data fusion approach for mobile ad hoc networks. *In: INTERNATIONAL CONFERENCE ON INFORMATION FUSION (FUSION)*, [s. L.]. 2005. [Proceedings ...]. S. l. 2005. Disponível em: https://ieeexplore-ieee-org.ez83.periodicos.capes.gov.br/stamp/stamp.jsp?tp=&arnumber=1591975. Acesso em: 29 dez. 2023.

MCDONALD, A. B. Arthur B. McDonald Nobel Lecture. 2015. Disponível em: https://www.nobelprize.org/prizes/physics/2015/mcdonald/lecture/. Acesso em: 05 fev. 2024.

MECANISMO de Higgs. 2024. Disponível em: https://pt.wikipedia.org/wiki/Mecanismo\_de\_Higgs. Acesso em: 05 fev. 2024.

MISTRY, K.; THOMPSON, A. J.; WILLIAMS, H. Data-MC shower shape comparisons : Supporting documentation for the Photon identification in 2015 ATLAS data. [s. l.]. 2016. Disponível em: https://cds.cern.ch/record/2154425? Acesso em: 29 dez. 2023.

MOREIRA, M. A. O conceito de simetria na física. *Revista do Professor de Física*, [s. l.].]: v. 3, n. 2, p. 1–8. 2019. Disponível em: https://periodicos.unb.br/index.php/rpf/article/download/26849/23373/54895. Acesso em: 29 dez. 2023.

MOURA JUNIOR, N. N. Modelo neural para a correção de estimativas de energia para um detector de partículas de propósito geral. 2014. Dissertação (Mestrado em Ciências em Engenharia Elétrica) — Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa em Engenharia, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2014.

MOURA JUNIOR, N. N. NeuralRinger results for Boosted Electrons Topologies and improvements. 2022. Disponível em: https://indico.cern.ch/event/1156408/ contributions/4856359/attachments/2435883/4172883/Natanael\_2022-05-03-QT\_ presentation\_printable.pdf. Acesso em: 10 nov. 2022.

NAKAMURA, K. et al. Particle Physics Booklet. [s.l.]: IOP, 2010.

NOVELLO, M. Do big bang ao Universo eterno. [s.l.]: Jorge Zahar, 2010.

NUNES, L. B. A. Deep learning approach for electron triggering even in boosted conditions. 2022. Disponível em: https://indico.cern.ch/event/1199261/contributions/ 5042191/attachments/2519252/4331725/20220929\_boosted\_meeting.pdf. Acesso em: 11 dez. 2023.

PARTICLE shower. 2023. Disponível em: https://en.wikipedia.org/wiki/Particle\_shower. Acesso em: 19 jun. 2023.

PERALVA, B. S. M. Reconstrução de Energia para Calorímetros Finamente Segmentados.
2015. Tese (Doutorado em Engenharia Elétrica) — Programa de Pós-graduação em Engenharia Elétrica, Universidade Federal de Juiz de Fora, Juiz de Fora, 2015.

PEREZ, G. M. Unitarization Models For Vector Boson Scattering at the LHC. 2018. Disponível em: https://www.researchgate.net/figure/ Coordinate-system-used-by-the-ATLAS-and-CMS-experiments-at-the-LHC-33\ \_fig4\\_326689955. Acesso em: 19 jun. 2023.

PERKINS, D. H. Introduction to High Energy Physics. [s.l.]: Addison-Wesley Publishing Company, 1972.

PINTO, J. V. F. Filtragem Online Segmentada Baseada em Redes Neurais Operando na Informação de um Calorímetro de Altas Energias de Fina Granularidade. 2022. Tese (Doutorado em Engenharia Elétrica) — Universidade Federal do Rio de Janeiro -COPPE, Rio de Janeiro, 2022.

PYTHIA. Disponível em: https://www.pythia.org/. Acesso em: 12 mar. 2024.

RASCHKA, S. Model Evaluation, Model Selection, and Algorithm Selection in Machine Learning. [s. 1.]. 2020. Acesso em: 29 dez. 2023.

RIEDMILLER, M.; BRAUN, H. A direct adaptive method for faster backpropagation learning: The rprop algorithm. *In: IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS*, San Francisco, 1993. [Proceedings ...]. San Francisco: IEEE. 1993. Acesso em: 29 dez. 2023.

RUIZ-MARTINEZ, A. The run-2 atlas trigger system. J. Phys.: Conf. Ser., [s.l.]. 2016. Disponível em: https://cds.cern.ch/record/2133909. Acesso em: 29 dez. 2023.

SCHäTZELA, S. Boosted top quarks and jet structure. *Eur. Phys. J. C*, [s.l.]. 2015. Disponível em: https://link.springer.com/article/10.1140/epjc/s10052-015-3636-x. Acesso em: 29 dez. 2023.

SEARS, F. W.; SALINGER, G. L. Termodinâmica, Teoria cinética e Termodinâmica Estatística. [s.l.]: Guanabara Dois, 1979.

SEIXAS, J. et al. Neural second-level trigger system based on calorimetry. [s.l.]. v. 95, p. 143–157, 1996. Disponível em: https://www.sciencedirect.com/science/article/abs/pii/0010465596000124. Acesso em: 29 dez. 2023.

SIMAS FILHO, E. F. de. Análise não-linear de componentes independentes para uma filtragem online baseada em calorímetria de alta energia e com fina segmentação. 2010. Tese (Doutorado em Engenharia Elétrica) — Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa em Engenharia, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2010.

TANABASHI, M. ET AL.  $J/\psi$ . 2018a. Disponível em: https://pdg.lbl.gov/2018/listings/rpp2018-list-J-psi-1S.pdf. Acesso em: 22 jan. 2024.

TANABASHI, M. ET AL. Υ. 2018b. Disponível em: https://pdg.lbl.gov/2018/listings/ rpp2018-list-upsilon-1S.pdf. Acesso em: 22 jan. 2024. TANABASHI, M. ET AL. *Gauge and Higgs Bosons.* 2019. Disponível em: https://pdg.lbl.gov/2019/tables/rpp2019-sum-gauge-higgs-bosons.pdf. Acesso em: 22 jan. 2024.

TAVERNIER, S. Experimental Techniques in Nuclear and Particle Physics. [s.l.]: Springer, 2010.

TENSORFLOW. Disponível em: https://www.tensorflow.org/?hl=pt-br. Acesso em: 01 de jan. de 2024.

THEVENEAUX-PELZER, T. Electron efficiency measurement at low energies with  $J/\Psi$  in ATLAS. EPS-HEP, [s. l.]. 2011. Disponível em: https://cds.cern.ch/record/1366338? Acesso em: 29 dez. 2023.

TORRES, R. C. Sistema online de filtragem em um ambiente com alta taxa de eventos e fina granularidade. 2010. Tese (Doutorado em Engenharia Elétrica) — Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa em Engenharia, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2010.

VALDIVIESSO, G. A.; GUZZO, M. M. Compreendendo a oscilação dos neutrinos. *Revista Brasileira de Ensino de Física*, [s. l.], v. 27, n. 4. 2005. Disponível em: https://www.scielo.br/j/rbef/a/RKtps8XYR4Zf9vbv8FpjKwm/#. Acesso em: 29 dez. 2023.

VOS, M. The atlas experiment: Boosted objects. [s.l.]. 2009. Disponível em: https://ific.uv.es/~vos/Atlas/Boost/. Acesso em: 29 dez. 2023.

VOS, M. *Boosted objects jet substructure*. 2014. Disponível em: https://indico.cern.ch/ event/282015/contributions/638779/attachments/518333/715127/VosBoostedObjects. pdf. Acesso em: 29 dez. 2023.

WEAK isospin. 2024. Disponível em: https://en.wikipedia.org/wiki/Weak\_isospin. Acesso em: 05 fev. 2024.

WEINBERG, S. A model of leptons. *Phys. Rev. Lett.*, [s.l.]. v. 19, 1967. Disponível em: https://journals.aps.org/prl/pdf/10.1103/PhysRevLett.19.1264. Acesso em: 29 dez. 2023.

WHALEN, K. From discovery to precision measurements: electron identification, electron-like backgrounds, and measurement of the differential fiducial cross-sections of the Higgs boson in the four-lepton decay channel with the ATLAS detector. 2015. Tese (Degree of Doctor of Philosophy) — Carleton University, Ottawa, 2015.

WOERDEN, M. C.; WILKENS, H.; SANTONI, C. Performance study of the atlas tile calorimeter using single muon events from  $w \to \mu\nu$  in 2010-2012 collision data. *ATL-COM-TILECAL-2015*, [s.l.]. v. 8, 2015. Disponível em: https://cds.cern.ch/record/1988094? Acesso em: 29 dez. 2023.

XAVIER, F. M. V. Recepção de sinal de múons no calorímetro hadrônico do experimento atlas. 2011. 96 f. Dissertação (Mestrado em Engenharia Elétrica) — Faculdade de Engenharia, Universidade Federal de Juiz de Fora, Juiz de Fora, 2011. Disponível em: https://repositorio.ufjf.br/jspui/handle/ufjf/2155.

XAVIER, T. C. Identificação online de sinais baseada em calorimetria de altas energias e com fina segmentação. 2012. Tese (Doutorado em Engenharia Elétrica) — Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa em Engenharia, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2012.

## **APÊNDICE A** – Tabelas de probabilidade de detecção

A tabela de propabilidade de detecção  $(P_D)$  apresenta os melhores modelos com a probabilidade de detecção fixa com o valor de referência (*Cutbase*), o índice SP e a taxa de falso alarme para todas as 25 regiões do espaço de fase. Abaixo, estão apresentadas as tabelas para os pontos de operação *medium*, *loose* e *very loose*.

Para o ponto de operação *Medium*, em 8 das 25 regiões, os modelos de fusão apresentam melhores eficiências que os outros em pelo menos 1  $\sigma$  de diferença. Para as outras regiões, permanecem na margem de erro. A tabela 6 apresenta a tabela de  $P_D$ para o ponto de operação *medium*.

Para o ponto de operação *loose*, em 10 das 25 regiões, os modelos de fusão apresentam melhores eficiências que os outros em pelo menos 1  $\sigma$  de diferença. Em uma região, somente o modelo de fusão com 4 variáveis de *shower shape*, V22 apresenta melhores resultados. Para as outras regiões, permanecem na margem de erro de 1  $\sigma$ . A tabela 7 apresenta a tabela de  $P_D$  para o ponto de operação *loose*.

Para o ponto de operação very loose, em 8 das 25 regiões, os modelos de fusão apresentam melhores eficiências que os outros em pelo menos 1  $\sigma$  de diferença. Em uma região, somente o modelo de fusão com 4 variáveis de shower shape, V22 apresenta melhores resultados. Para as outras regiões, permanecem na margem de erro de 1  $\sigma$ . A tabela 8 apresenta a tabela de  $P_D$  para o ponto de operação very loose.

Vale ressaltar que para os pontos de operação *loose* e very *loose*, usamos todas as regiões do barril  $(0,00 < |\eta| < 0,80)$  e do barril estendido  $(0,80 < |\eta| < 1,37)$  com melhores resultados para os modelo de fusão (V21New e V22) e principalmente para o modelo de fusão com 4 variáveis de shower shape (V22), pois na região  $0,00 < |\eta| <$ 0,80 de  $40 < E_T < 50$  GeV, somente ele que apresenta diferença maior que 1  $\sigma$  dos outros modelos (sem contar com V21New). Além disso, os modelos de fusão (V21New e V22) estão com resultados melhores em todos os pontos de operação na região da tampa  $(1,54 < |\eta| < 2,37)$  no intervalo de menor energia  $(15 < E_T < 20 \text{ GeV})$ .

	0	1 3						•	neate 1	1	•	,					
		Line and the second second		$15 < 5 [C_{1}] < 20$			20 < E [C-1/] < 20		1	20 < 5 [C-1/] < 40		1	40 < E [C, M] < E			$\Gamma \left[ C \right] = \Gamma 0$	
		kinematic region		$15 < E_T[GeV] < 20$			$20 < E_T[GeV] < 30$			$30 < E_T[GeV] < 40$	)		$40 < E_T[GeV] < 50$	)		$E_T[GeV] > 50$	
Det. Region	Method	Туре	$P_{D}[\%]$	SP[%]	$F_R[\%]$	$P_{D}[\%]$	SP[%]	$F_R[\%]$	$P_{D}[\%]$	SP[%]	$F_R[\%]$	$P_{D}[\%]$	SP[%]	$F_R[\%]$	$P_{D}[\%]$	SP[%]	$F_R[\%]$
	Cut-Based (2017)	Reference	97.84	92.35	12.97	98.87	94.21	10.33	99.34	95.29	8.68	99.68	95.53	8.53	99.73	87.16	24.55
	V8	Cross Val.	97.84±0.00	97.60±0.10	$2.64 \pm 0.20$	$98.86 \pm 0.00$	98.52±0.03	$1.83 {\pm} 0.06$	99.34±0.00	99.13±0.04	$1.08 \pm 0.09$	99.68±0.00	99.37±0.04	$0.94 {\pm} 0.08$	99.73±0.00	$99.56 \pm 0.01$	0.60±0.02
	V12	Cross Val.	97.83±0.01	97.50±0.10	$2.84 \pm 0.19$	98.86±0.00	98.45±0.06	$1.97 \pm 0.13$	99.34±0.01	99.08±0.06	$1.17 \pm 0.12$	99.68±0.00	99.31±0.04	$1.06 {\pm} 0.07$	99.73±0.00	$99.56 \pm 0.01$	$0.61 \pm 0.02$
0.00 0.00	Vss.new	Cross Val.	97.84±0.00	96.59±0.08	$4.66 {\pm} 0.16$	98.87±0.00	$97.21 {\pm} 0.07$	$4.43 {\pm} 0.14$	99.34±0.00	97.82±0.04	$3.69 \pm 0.08$	99.68±0.00	97.99±0.09	$3.70 {\pm} 0.17$	99.73±0.00	98.90±0.06	$1.93 {\pm} 0.11$
$0.00 < \eta < 0.80$	V21 new	Cross Val	97.83+0.01	97.87+0.04	$2.08 \pm 0.09$	98.87+0.01	98.69+0.02	$1.49 \pm 0.05$	99.34+0.00	$99.21 \pm 0.04$	$0.91 \pm 0.08$	99.68+0.00	99.44±0.04	$0.81 \pm 0.07$	99.73+0.00	$99.61 \pm 0.01$	$0.50 \pm 0.02$

Tabela 6 - Tabela de probabilidade de detecção que apresenta os valores de  $P_D$  (verde),  $SP \in P_F$  ( $F_R$ ) (falso alarme ou eficiência de *background*) para cada região do espaço de fase com os melhores modelos selecionados pelo  $SP_{max}$  para o ponto de operação *medium* 

Det. Region	Method	Type	$P_D[\%]$	SP[%]	$F_R[\%]$	$P_D[\%]$	SP[%]	$F_R[\%]$	$P_D[\%]$	SP[%]	$F_R[\%]$	$P_D[\%]$	SP[%]	$F_R[\%]$	$P_D[\%]$	SP[%]	$F_R[\%]$
	Cut-Based (2017)	Reference	97.84	92.35	12.97	98.87	94.21	10.33	99.34	95.29	8.68	99.68	95.53	8.53	99.73	87.16	24.55
	V8	Cross Val.	97.84±0.00	$97.60 \pm 0.10$	$2.64 \pm 0.20$	98.86±0.00	$98.52 \pm 0.03$	$1.83 \pm 0.06$	99.34±0.00	$99.13 \pm 0.04$	$1.08 {\pm} 0.09$	$99.68 \pm 0.00$	99.37±0.04	$0.94 \pm 0.08$	99.73±0.00	$99.56 {\pm} 0.01$	$0.60 \pm 0.02$
	V12	Cross Val.	$97.83 \pm 0.01$	$97.50 \pm 0.10$	$2.84{\pm}0.19$	98.86±0.00	$98.45 \pm 0.06$	$1.97 \pm 0.13$	99.34±0.01	$99.08 \pm 0.06$	$1.17 \pm 0.12$	99.68±0.00	99.31±0.04	$1.06 \pm 0.07$	99.73±0.00	$99.56 {\pm} 0.01$	$0.61 \pm 0.02$
0.00 < n < 0.80	Vss.new	Cross Val.	$97.84 \pm 0.00$	$96.59 \pm 0.08$	$4.66 {\pm} 0.16$	98.87±0.00	$97.21 \pm 0.07$	$4.43 \pm 0.14$	99.34±0.00	97.82±0.04	$3.69 \pm 0.08$	99.68±0.00	$97.99 \pm 0.09$	$3.70 \pm 0.17$	99.73±0.00	$98.90 \pm 0.06$	$1.93 {\pm} 0.11$
0.00 < 1 < 0.00	V21.new	Cross Val.	$97.83 \pm 0.01$	97.87±0.04	$2.08 \pm 0.09$	98.87±0.01	$98.69 \pm 0.02$	$1.49 \pm 0.05$	99.34±0.00	$99.21 \pm 0.04$	$0.91 {\pm} 0.08$	99.68±0.00	99.44±0.04	$0.81 \pm 0.07$	99.73±0.00	$99.61 {\pm} 0.01$	$0.50 \pm 0.02$
	Vss5var	Cross Val.	97.84±0.00	$96.40 \pm 0.11$	$5.03 \pm 0.22$	98.87±0.00	97.03±0.07	$4.80 \pm 0.13$	99.34±0.00	$97.62 \pm 0.05$	$4.09 \pm 0.10$	99.68±0.00	97.76±0.07	$4.15 \pm 0.14$	99.73±0.00	$98.75 \pm 0.07$	$2.23 \pm 0.13$
	Vss4var	Cross Val.	97.84±0.00	$95.20 \pm 0.17$	$7.39 \pm 0.34$	98.87±0.00	$96.17 \pm 0.05$	$6.48 \pm 0.11$	99.34±0.00	$97.12 \pm 0.09$	$5.07 \pm 0.18$	$99.68 \pm 0.00$	$97.29 \pm 0.06$	$5.08 \pm 0.12$	99.73±0.00	$97.41 \pm 0.08$	$4.88 \pm 0.16$
	V22	Cross Val.	$97.84 \pm 0.01$	$97.86 \pm 0.05$	$2.13 \pm 0.09$	98.87±0.00	98.70±0.04	$1.46 {\pm} 0.07$	99.34±0.00	99.22±0.04	$0.91 {\pm} 0.08$	$99.68 {\pm} 0.01$	99.44±0.04	$0.81 \pm 0.08$	99.73±0.00	$99.60 {\pm} 0.01$	0.53±0.03
	Cut-Based (2017)	Reference	97.78	87.45	22.31	99.15	90.15	18.42	99.60	91.45	16.36	99.79	91.39	16.63	99.76	83.36	31.56
	V8	Cross Val.	$97.77 \pm 0.01$	$96.72 \pm 0.10$	$4.32 \pm 0.19$	$99.15 \pm 0.00$	$97.80 {\pm} 0.06$	$3.54 \pm 0.12$	$99.60 {\pm} 0.00$	$98.61 \pm 0.08$	$2.38 {\pm} 0.16$	99.79±0.00	$98.95 \pm 0.08$	$1.88 {\pm} 0.16$	99.76±0.00	$99.19 {\pm} 0.02$	$1.38 {\pm} 0.04$
	V12	Cross Val.	97.78±0.01	$96.55 \pm 0.06$	$4.68 \pm 0.12$	$99.15 \pm 0.00$	$97.65 \pm 0.07$	$3.83 \pm 0.13$	$99.60 {\pm} 0.00$	$98.50 \pm 0.07$	$2.59 \pm 0.14$	99.79±0.00	$98.85 \pm 0.07$	$2.09 \pm 0.15$	99.76±0.00	$99.15 \pm 0.04$	$1.46 {\pm} 0.08$
0.80 < n < 1.37	Vss.new	Cross Val.	97.77±0.00	$96.10 \pm 0.06$	$5.56 \pm 0.12$	$99.15 \pm 0.00$	$96.86 \pm 0.06$	$5.40 \pm 0.13$	$99.60 {\pm} 0.00$	$97.54 \pm 0.07$	$4.50 \pm 0.14$	99.79±0.00	$97.80 \pm 0.10$	$4.16 \pm 0.20$	99.76±0.00	$98.57 \pm 0.10$	$2.61 \pm 0.20$
0.00 < 11 < 1.51	V21.new	Cross Val.	$97.77 \pm 0.01$	$97.19 \pm 0.07$	$3.39 \pm 0.13$	$99.15 \pm 0.00$	$98.15 \pm 0.05$	$2.85 \pm 0.10$	99.60±0.00	$98.83 \pm 0.05$	$1.94{\pm}0.10$	99.79±0.00	99.08±0.07	$1.62 \pm 0.14$	99.76±0.00	$99.28 \pm 0.03$	$1.19{\pm}0.06$
	Vss5var	Cross Val.	$97.77 \pm 0.01$	$95.66 \pm 0.08$	$6.44 {\pm} 0.16$	99.15±0.00	$96.34 \pm 0.10$	$6.42 \pm 0.19$	99.60±0.00	$97.08 \pm 0.10$	$5.42 \pm 0.20$	99.79±0.00	$97.32 \pm 0.11$	$5.11 \pm 0.22$	99.76±0.00	$98.05 \pm 0.08$	$3.65 \pm 0.17$
	Vss4var	Cross Val.	$97.77 \pm 0.01$	$94.11 \pm 0.17$	9.49±0.33	99.15±0.00	95.34±0.08	$8.39 \pm 0.16$	99.60±0.00	96.42±0.09	$6.71 \pm 0.19$	99.79±0.00	96.85±0.09	$6.05 \pm 0.19$	99.76±0.00	$96.88 \pm 0.14$	5.96±0.28
	V22	Cross Val.	97.77±0.01	$97.10 {\pm} 0.07$	$3.56 {\pm} 0.15$	$99.15 \pm 0.00$	$98.12 \pm 0.05$	$2.91 \pm 0.11$	$99.60 {\pm} 0.00$	$98.82 \pm 0.05$	$1.96{\pm}0.10$	$99.79 \pm 0.00$	$99.08 \pm 0.06$	$1.63 \pm 0.13$	99.76±0.00	99.28±0.02	$1.21 \pm 0.04$
	Cut-Based (2017)	Reference	97.00	74.21	45.51	94.73	83.59	26.86	96.88	88.42	19.66	97.30	89.55	17.89	98.31	49.02	82.49
	V8	Cross Val.	$97.00 \pm 0.01$	$91.69 \pm 0.70$	$13.47 \pm 1.37$	94.73±0.03	$95.53 \pm 0.16$	$3.66 \pm 0.32$	96.86±0.04	$97.20 \pm 0.10$	$2.46 \pm 0.20$	97.27±0.08	$97.61 \pm 0.11$	$2.05 \pm 0.22$	$98.31 \pm 0.01$	$98.54 \pm 0.07$	$1.22 \pm 0.14$
	V12	Cross Val.	$97.00 \pm 0.01$	$91.20 \pm 0.66$	$14.42 \pm 1.28$	94.74±0.02	$95.22 \pm 0.18$	4.29±0.34	96.87±0.03	$96.91 {\pm} 0.11$	$3.06 \pm 0.21$	97.34±0.06	97.45±0.13	$2.44 \pm 0.25$	98.31±0.00	$98.47 \pm 0.15$	$1.38 {\pm} 0.31$
137 < n < 154	Vss.new	Cross Val.	97.02±0.06	67.23±2.06	$56.99 \pm 3.29$	94.73±0.01	$81.97 \pm 1.28$	$29.85 \pm 2.37$	$96.88 {\pm} 0.01$	$84.49 \pm 1.41$	$27.04 \pm 2.61$	97.31±0.02	$85.40 \pm 1.06$	$25.73 \pm 1.98$	$98.31 \pm 0.00$	86.37±2.66	24.76±4.90
1.57 < 17 < 1.54	V21.new	Cross Val.	$97.01 \pm 0.01$	$91.55 \pm 0.79$	$13.74{\pm}1.53$	94.73±0.02	$95.34 \pm 0.18$	4.04±0.36	96.86±0.07	$97.07 \pm 0.17$	$2.73 \pm 0.35$	97.32±0.05	$97.50 \pm 0.12$	$2.31 \pm 0.25$	98.31±0.00	$98.58 \pm 0.04$	$1.15 {\pm} 0.08$
	Vss5var	Cross Val.	$97.00 \pm 0.01$	$65.93 \pm 2.55$	$59.00 \pm 3.92$	94.73±0.01	$75.81 \pm 1.26$	$40.98 \pm 2.21$	96.88±0.00	$76.54 \pm 1.89$	$41.37 \pm 3.26$	$97.30 {\pm} 0.01$	$79.08 \pm 1.81$	$37.22 \pm 3.18$	98.31±0.00	$76.76 \pm 3.57$	$42.03 \pm 6.14$
	Vss4var	Cross Val.	97.00±0.01	60.63±1.20	67.00±1.74	94.78±0.16	68.32±2.63	53.70±4.37	96.88±0.00	$72.50 {\pm} 0.75$	48.32±1.27	97.30±0.01	$75.60 \pm 1.38$	43.33±2.38	98.44±0.39	$68.95 \pm 8.36$	54.47±11.86
	V22	Cross Val.	$96.99 {\pm} 0.01$	$91.38 {\pm} 0.73$	$14.06 \pm 1.42$	94.72±0.03	$95.32 \pm 0.15$	4.07±0.29	96.87±0.04	$97.05 \pm 0.19$	$2.77 \pm 0.36$	97.32±0.06	97.48±0.15	2.37±0.28	98.31±0.00	98.56±0.06	$1.19{\pm}0.12$
	Cut-Based (2017)	Reference	97.63	87.91	21.29	98.45	91.31	15.55	99.12	92.83	13.26	99.32	92.90	13.31	99.41	79.80	37.64
	V8	Cross Val.	$97.63 \pm 0.00$	96.47±0.08	$4.68 {\pm} 0.16$	98.45±0.00	$97.41 \pm 0.09$	$3.63 \pm 0.18$	$99.11 \pm 0.01$	$98.25 \pm 0.06$	$2.61 \pm 0.13$	99.33±0.01	$98.69 \pm 0.07$	$1.94 {\pm} 0.14$	99.41±0.00	$98.66 {\pm} 0.03$	$2.09 \pm 0.05$
	V12	Cross Val.	97.63±0.00	$96.45 \pm 0.20$	4.73±0.40	98.45±0.00	$97.47 \pm 0.17$	$3.50 \pm 0.33$	$99.12 \pm 0.00$	$98.29 \pm 0.12$	$2.53 \pm 0.24$	$99.32 \pm 0.01$	$98.69 \pm 0.07$	$1.94 \pm 0.14$	99.41±0.00	98.80±0.09	$1.81 \pm 0.18$
154 < n < 237	Vss.new	Cross Val.	$97.63 \pm 0.00$	$94.23 \pm 0.12$	$9.12 \pm 0.24$	98.45±0.00	$95.46 \pm 0.08$	$7.48 \pm 0.15$	$99.12 \pm 0.00$	$96.63 \pm 0.09$	$5.82 \pm 0.17$	99.32±0.00	$97.09 \pm 0.11$	$5.11 \pm 0.22$	99.41±0.00	$97.25 \pm 0.13$	4.88±0.25
1.54 < 1 < 2.51	V21.new	Cross Val.	$97.63 \pm 0.01$	$96.76 \pm 0.06$	$4.10 \pm 0.11$	98.45±0.00	$97.65 \pm 0.08$	$3.14 \pm 0.15$	$99.12 \pm 0.01$	$98.41 \pm 0.05$	$2.29 \pm 0.10$	$99.32 \pm 0.01$	98.78±0.08	$1.76 \pm 0.17$	$99.41 \pm 0.00$	98.73±0.04	$1.96 \pm 0.07$
	Vss5var	Cross Val.	97.63±0.00	$93.28 \pm 0.15$	$10.98 {\pm} 0.29$	98.45±0.00	94.78±0.09	$8.82 \pm 0.17$	$99.12 \pm 0.00$	$96.06 \pm 0.13$	$6.95 \pm 0.25$	99.32±0.00	$96.71 \pm 0.10$	$5.87 \pm 0.21$	99.41±0.00	96.58±0.28	$6.21 \pm 0.55$
	Vss4var	Cross Val.	$97.63 \pm 0.00$	$91.93 \pm 0.21$	$13.60 {\pm} 0.41$	98.45±0.00	$93.58 \pm 0.13$	$11.16 \pm 0.25$	$99.12 \pm 0.00$	$95.16 \pm 0.13$	$8.72 \pm 0.25$	99.32±0.00	$95.66 \pm 0.12$	7.93±0.24	99.41±0.00	$93.78 \pm 0.24$	$11.68 \pm 0.46$
	V22	Cross Val.	$97.63 \pm 0.01$	$96.76 \pm 0.08$	$4.11 \pm 0.16$	98.44±0.00	$97.66 \pm 0.07$	$3.12 \pm 0.14$	$99.12 \pm 0.00$	98.42±0.04	$2.27 \pm 0.09$	$99.32 \pm 0.01$	98.78±0.07	$1.77 \pm 0.14$	$99.41 \pm 0.00$	$98.69 \pm 0.04$	$2.03 \pm 0.08$
	Cut-Based (2017)	Reference	93.02	70.22	49.34	95.68	74.20	44.52	96.70	77.02	40.42	97.12	77.23	40.38	96.01	52.39	77.61
	V8	Cross Val.	93.02±0.12	94.08±0.36	$4.84 \pm 0.74$	95.68±0.06	$96.01 \pm 0.14$	$3.66 \pm 0.27$	$96.69 \pm 0.13$	$97.17 \pm 0.15$	$2.34 \pm 0.34$	96.99±0.24	97.72±0.13	$1.54 \pm 0.18$	96.00±0.06	97.60±0.06	0.79±0.08
	V12	Cross Val.	93.00±0.13	$93.91 \pm 0.40$	$5.17 \pm 0.81$	95.67±0.04	$95.89 \pm 0.14$	$3.89 \pm 0.27$	$96.68 \pm 0.12$	$97.09 \pm 0.14$	$2.49 \pm 0.32$	$97.10 \pm 0.13$	97.73±0.14	$1.64 \pm 0.22$	$96.00 \pm 0.06$	$97.58 \pm 0.05$	$0.83 {\pm} 0.09$
237 < n < 250	Vss.new	Cross Val.	93.08±0.08	$89.80 {\pm} 0.68$	$13.42 \pm 1.30$	95.68±0.03	$91.58 \pm 0.37$	$12.42 \pm 0.72$	$96.70 \pm 0.01$	$93.10 {\pm} 0.39$	$10.43 {\pm} 0.76$	97.13±0.02	93.45±0.63	$10.15 \pm 1.22$	$96.01 \pm 0.01$	94.13±0.37	7.73±0.73
2.51 < 11 < 2.50	V21.new	Cross Val.	93.08±0.14	$93.96 {\pm} 0.32$	$5.15 \pm 0.68$	$95.66 \pm 0.05$	$95.98 \pm 0.13$	$3.71 \pm 0.25$	$96.68 \pm 0.13$	$97.12 \pm 0.13$	$2.43 \pm 0.27$	97.12±0.13	$97.77 \pm 0.10$	$1.57 {\pm} 0.20$	96.03±0.14	$97.59 {\pm} 0.10$	$0.83 {\pm} 0.10$
	Vss5var	Cross Val.	93.01±0.04	88.70±0.42	$15.50 {\pm} 0.83$	95.68±0.02	$89.95 \pm 0.29$	$15.61 {\pm} 0.56$	96.70±0.02	$90.81 \pm 1.30$	$14.88 {\pm} 2.49$	$97.12 \pm 0.04$	$91.78 \pm 0.74$	$13.40 \pm 1.44$	$96.01 \pm 0.01$	$91.68 {\pm} 0.52$	$12.54 \pm 1.02$
	Vss4var	Cross Val.	93.04±0.06	$85.78 \pm 0.86$	$21.18 {\pm} 1.65$	95.67±0.01	87.36±0.79	$20.57 \pm 1.50$	96.70±0.02	88.07±0.77	$20.15 \pm 1.47$	97.12±0.03	$88.58 {\pm} 0.70$	$19.56 {\pm} 1.34$	96.00±0.00	88.22±0.99	$19.24 {\pm} 1.90$
	V22	Cross Val.	93.00±0.08	$93.80 {\pm} 0.35$	$5.40 {\pm} 0.69$	95.70±0.04	$95.98 {\pm} 0.11$	$3.74 \pm 0.22$	96.73±0.17	$97.14 \pm 0.21$	$2.44 \pm 0.33$	97.11±0.17	$97.75 \pm 0.14$	$1.61 {\pm} 0.21$	$96.01 \pm 0.05$	$97.59 {\pm} 0.05$	$0.82{\pm}0.10$

Fonte: O autor, 2024.

Tabela 7 -	Tabela de probabilidade de detecção que apresenta os valores de $P_D$ (verde), $SP \in P_F$ ( $F_R$ ) (falso alarme ou eficiência de <i>background</i> ) para cada
	região do espaço de fase com os melhores modelos selecionados pelo $SP_{max}$ para o ponto de operação $loose$

		kinematic region		$15 < E_T[GeV] < 20$			$20 < E_T[GeV] < 30$			$30 < E_T[GeV] < 40$			$40 < E_T[GeV] < 50$			$E_T[GeV] > 50$	
Det. Region	Method	Туре	$P_D[\%]$	SP[%]	$F_R[\%]$	$P_D[\%]$	SP[%]	$F_R[\%]$	$P_D[\%]$	SP[%]	$F_R[\%]$	$P_D[\%]$	SP[%]	$F_R[\%]$	$P_D[\%]$	SP[%]	$F_R[\%]$
	Cut-Based (2017)	Reference	98.79	90.73	16.98	99.43	84.34	29.50	99.80	82.75	32.69	99.93	83.28	31.85	99.97	39.93	91.38
	V8	Cross Val.	98.79±0.00	97.57±0.09	$3.65 {\pm} 0.18$	99.43±0.00	$98.41 \pm 0.05$	$2.60 \pm 0.10$	99.80±0.00	98.98±0.05	$1.82 \pm 0.09$	99.93±0.00	99.06±0.05	$1.81 {\pm} 0.09$	99.97±0.00	$99.22 \pm 0.08$	$1.52 \pm 0.15$
	V12	Cross Val.	98.79±0.00	97.45±0.10	$3.87 \pm 0.21$	99.43±0.00	98.35±0.08	$2.73 \pm 0.15$	99.80±0.00	$98.91 \pm 0.06$	$1.97 \pm 0.13$	99.93±0.00	98.97±0.07	$1.98 {\pm} 0.13$	99.97±0.00	99.23±0.10	$1.50 {\pm} 0.20$
0.00 < - < 0.90	Vss.new	Cross Val.	98.79±0.00	96.20±0.12	6.36±0.24	99.43±0.00	96.63±0.16	$6.13 \pm 0.31$	99.80±0.00	96.75±0.23	$6.25 \pm 0.46$	99.93±0.00	96.62±0.30	$6.65 \pm 0.59$	99.97±0.00	96.41±0.91	7.08±1.79
$0.00 < \eta < 0.80$	V21.new	Cross Val.	98.79±0.00	$97.98 \pm 0.09$	$2.82 {\pm} 0.19$	99.43±0.00	98.70±0.05	$2.02 \pm 0.09$	99.80±0.00	99.12±0.05	$1.56 {\pm} 0.10$	99.93±0.00	$99.17 \pm 0.12$	$1.59 \pm 0.23$	99.97±0.00	99.43±0.05	$1.11 {\pm} 0.11$
	Vss5var	Cross Val.	98.79±0.00	$95.91 \pm 0.10$	$6.93 \pm 0.20$	99.43±0.00	96.34±0.14	$6.71 \pm 0.27$	99.80±0.00	96.22±0.31	$7.29 {\pm} 0.61$	99.93±0.00	96.12±0.34	$7.61 \pm 0.66$	99.97±0.00	$95.32 \pm 1.28$	9.22±2.50
	Vss4var	Cross Val.	98.79±0.00	$94.46 \pm 0.17$	$9.76 \pm 0.33$	99.43±0.00	$95.29 \pm 0.12$	8.76±0.23	99.80±0.00	$95.69 \pm 0.16$	$8.33 \pm 0.32$	99.93±0.00	$95.36 \pm 0.17$	$9.10 {\pm} 0.33$	$99.97 \pm 0.00$	$92.16 {\pm} 0.91$	$15.33 \pm 1.74$
	V22	Cross Val.	98.79±0.00	$97.95 \pm 0.10$	$2.88 {\pm} 0.21$	99.43±0.00	98.68±0.04	$2.06 \pm 0.08$	99.80±0.00	$99.11 \pm 0.05$	$1.58 {\pm} 0.10$	99.93±0.00	$99.18 {\pm} 0.05$	$1.58 {\pm} 0.10$	99.97±0.00	99.41±0.04	$1.14{\pm}0.08$
	Cut-Based (2017)	Reference	98.67	84.31	28.91	99.55	75.36	45.43	99.88	72.02	51.24	99.96	71.85	51.57	99.92	37.74	92.91
	V8	Cross Val.	98.67±0.00	96.54±0.14	$5.56 {\pm} 0.28$	99.55±0.00	97.47±0.08	$4.60 {\pm} 0.15$	99.88±0.00	98.07±0.08	$3.73 \pm 0.17$	99.97±0.00	$98.15 \pm 0.10$	$3.65 \pm 0.21$	99.92±0.00	98.94±0.03	$2.05 \pm 0.06$
	V12	Cross Val.	98.67±0.00	$96.35 \pm 0.11$	$5.94 \pm 0.23$	99.55±0.00	97.30±0.07	$4.93 \pm 0.14$	99.88±0.00	97.93±0.09	$4.00 \pm 0.19$	99.96±0.00	98.04±0.12	$3.87 \pm 0.23$	$99.92 {\pm} 0.00$	98.92±0.06	$2.08 \pm 0.11$
0.80 < n < 1.37	Vss.new	Cross Val.	98.67±0.00	$95.80 \pm 0.12$	$7.03 \pm 0.25$	$99.55 {\pm} 0.00$	96.23±0.14	7.03±0.27	99.88±0.00	96.44±0.10	$6.94{\pm}0.20$	99.97±0.00	$96.34 \pm 0.17$	$7.22 \pm 0.34$	$99.92{\pm}0.00$	97.86±0.33	$4.18 {\pm} 0.65$
0.00 < 1 < 1.51	V21.new	Cross Val.	98.67±0.00	97.21±0.09	$4.25 \pm 0.19$	99.55±0.00	97.94±0.05	$3.67 \pm 0.10$	99.88±0.00	98.44±0.07	$3.00 \pm 0.15$	99.96±0.00	98.50±0.09	$2.96 \pm 0.18$	99.92±0.00	$99.10 \pm 0.04$	$1.73 \pm 0.09$
	Vss5var	Cross Val.	98.67±0.00	95.23±0.16	$8.15 {\pm} 0.31$	99.55±0.00	$95.52 \pm 0.13$	8.43±0.26	99.88±0.00	$95.51 \pm 0.13$	$8.76 \pm 0.25$	99.97±0.00	$95.29 \pm 0.22$	$9.27 \pm 0.43$	$99.92 {\pm} 0.00$	96.72±0.32	6.43±0.63
	Vss4var	Cross Val.	98.67±0.00	93.26±0.31	$11.99 {\pm} 0.60$	99.55±0.00	94.24±0.12	$10.92 \pm 0.24$	99.88±0.00	94.74±0.15	$10.27 \pm 0.29$	99.97±0.00	94.57±0.31	$10.68 {\pm} 0.61$	99.92±0.00	$95.13 \pm 0.40$	9.54±0.79
	V22	Cross Val.	98.67±0.01	97.07±0.09	$4.52 \pm 0.17$	$99.55 \pm 0.00$	97.88±0.06	$3.77 \pm 0.11$	99.88±0.00	98.42±0.08	$3.02{\pm}0.16$	99.97±0.00	98.45±0.06	$3.05 \pm 0.11$	$99.92{\pm}0.00$	$99.09 \pm 0.05$	$1.75 {\pm} 0.09$
	Cut-Based (2017)	Reference	97.52	70.03	52.86	96.16	81.13	32.61	97.66	86.06	24.80	97.72	87.36	22.43	98.53	43.21	88.35
	V8	Cross Val.	97.52±0.01	90.21±1.00	$16.81{\pm}1.91$	96.16±0.03	95.87±0.18	$4.42 \pm 0.35$	97.68±0.03	$97.39 \pm 0.10$	$2.89 \pm 0.19$	97.72±0.04	97.76±0.13	$2.20 \pm 0.23$	98.53±0.00	$98.58 \pm 0.08$	$1.37 \pm 0.16$
	V12	Cross Val.	97.52±0.00	89.52±1.22	$18.12 \pm 2.33$	$96.15 \pm 0.02$	$95.50 \pm 0.19$	$5.16 \pm 0.38$	97.64±0.02	97.05±0.15	$3.53 \pm 0.28$	97.71±0.06	$97.51 \pm 0.15$	$2.69 \pm 0.26$	98.53±0.00	$98.51 \pm 0.17$	$1.50 {\pm} 0.34$
1.37 < n < 1.54	Vss.new	Cross Val.	97.52±0.01	64.94±2.24	60.86±3.43	$96.16 \pm 0.00$	$80.15 \pm 1.60$	34.37±2.88	97.66±0.00	83.12±1.54	$30.24 \pm 2.81$	97.72±0.00	$84.65 \pm 1.19$	$27.46 \pm 2.21$	98.53±0.00	85.44±2.80	$26.67 \pm 5.13$
1.01 ( 1 ( 1.01	V21.new	Cross Val.	97.52±0.01	90.16±1.42	$16.90 {\pm} 2.72$	96.17±0.02	95.67±0.17	4.83±0.34	97.66±0.03	97.21±0.22	$3.23 \pm 0.44$	97.71±0.05	$97.61 \pm 0.14$	$2.48 \pm 0.27$	$98.53 \pm 0.00$	$98.63 \pm 0.05$	$1.27 \pm 0.09$
	Vss5var	Cross Val.	97.52±0.01	63.33±2.35	$63.29 \pm 3.48$	$96.16 \pm 0.00$	$73.18 \pm 1.29$	$46.63 \pm 2.18$	97.66±0.01	$74.50 \pm 2.08$	$45.47 \pm 3.50$	97.72±0.01	$77.95 \pm 2.02$	$39.55 \pm 3.49$	$98.53 \pm 0.00$	75.07±3.96	$45.06 \pm 6.68$
	Vss4var	Cross Val.	97.51±0.01	$58.66 \pm 1.10$	$70.08 {\pm} 1.53$	$96.16 \pm 0.01$	$66.04 \pm 1.65$	$58.31 \pm 2.61$	97.66±0.00	$70.62 \pm 0.98$	$51.99 {\pm} 1.61$	97.72±0.01	74.58±1.42	$45.40 \pm 2.42$	98.63±0.32	$68.12 \pm 8.12$	$55.97 \pm 11.43$
	V22	Cross Val.	97.52±0.01	89.71±1.22	$17.76 \pm 2.33$	96.16±0.02	95.64±0.16	4.88±0.32	97.67±0.03	97.17±0.23	$3.32 \pm 0.46$	97.71±0.03	97.57±0.12	$2.57 \pm 0.24$	98.53±0.00	98.61±0.06	$1.30 \pm 0.12$
	Cut-Based (2017)	Reference	98.25	83.99	29.14	99.40	82.76	32.35	99.86	82.70	32.83	99.95	82.97	32.42	99.98	42.83	89.06
	V8	Cross Val.	98.25±0.00	96.46±0.08	$5.32 \pm 0.15$	99.40±0.00	$97.19 \pm 0.14$	$5.00 \pm 0.28$	99.86±0.00	$97.71 \pm 0.07$	$4.42 \pm 0.13$	$99.95 \pm 0.00$	$98.03 \pm 0.14$	$3.87 \pm 0.27$	$99.98 \pm 0.00$	$97.02 \pm 0.31$	$5.89 \pm 0.61$
	V12	Cross Val.	$98.25 \pm 0.01$	96.47±0.22	$5.29 \pm 0.43$	99.40±0.00	$97.30 {\pm} 0.19$	$4.79 \pm 0.38$	99.86±0.00	$97.85 \pm 0.19$	$4.15 \pm 0.39$	99.95±0.00	$98.07 \pm 0.11$	$3.80 \pm 0.21$	$99.98 \pm 0.00$	$97.46 \pm 0.36$	$5.03 \pm 0.71$
1.54 < n < 2.37	Vss.new	Cross Val.	98.25±0.00	$93.99 \pm 0.11$	$10.18 \pm 0.22$	$99.40 \pm 0.00$	$94.52 \pm 0.18$	$10.24 \pm 0.36$	99.86±0.00	95.00±0.23	$9.74 \pm 0.45$	$99.95 \pm 0.00$	$94.88 \pm 0.15$	$10.06 \pm 0.30$	$99.98 \pm 0.00$	$91.97 \pm 0.66$	$15.70 \pm 1.27$
	V21.new	Cross Val.	98.25±0.00	$96.84 \pm 0.07$	$4.56 \pm 0.15$	99.40±0.00	$97.57 \pm 0.11$	$4.24 \pm 0.22$	$99.86 \pm 0.00$	$98.02 \pm 0.09$	$3.81 \pm 0.18$	$99.95 \pm 0.00$	$98.21 \pm 0.12$	$3.51 \pm 0.24$	$99.98 \pm 0.00$	$97.55 \pm 0.19$	$4.85 \pm 0.39$
	Vss5var	Cross Val.	98.25±0.00	$92.79 \pm 0.17$	$12.50 \pm 0.34$	$99.40 \pm 0.00$	$93.44 \pm 0.15$	$12.33 \pm 0.30$	$99.86 \pm 0.00$	$93.81 \pm 0.32$	$12.04 \pm 0.61$	$99.95 \pm 0.00$	$93.97 \pm 0.35$	$11.82 \pm 0.67$	$99.98 \pm 0.00$	$89.79 \pm 1.80$	$19.83 \pm 3.39$
	Vss4var	Cross Val.	98.25±0.00	$91.23 \pm 0.30$	$15.52 \pm 0.58$	99.40±0.00	$91.91 \pm 0.26$	$15.29 \pm 0.50$	99.86±0.00	$92.69 \pm 0.25$	$14.22 \pm 0.47$	99.95±0.00	$92.42 \pm 0.34$	$14.82 \pm 0.65$	$99.98 \pm 0.00$	82.43±1.95	$33.40 \pm 3.49$
	V22	Cross Val.	$98.25 \pm 0.01$	96.84±0.08	$4.56 \pm 0.17$	99.40±0.00	97.54±0.10	$4.30 \pm 0.19$	99.86±0.00	97.99±0.07	$3.87 \pm 0.15$	$99.95 \pm 0.00$	$98.15 \pm 0.14$	$3.63 \pm 0.27$	$99.98 \pm 0.00$	$97.28 \pm 0.28$	5.37±0.54
	Cut-Based (2017)	Reference	93.50	61.65	63.46	95.69	71.88	48.50	96.70	76.42	41.45	97.12	76.62	41.43	96.01	51.79	78.35
	V8	Cross Val.	93.40±0.24	$94.18 \pm 0.40$	$5.04 \pm 0.86$	95.68±0.06	$96.01 \pm 0.14$	$3.67 \pm 0.28$	96.69±0.13	97.17±0.15	$2.34 \pm 0.34$	96.99±0.24	$97.72 \pm 0.13$	$1.54 \pm 0.18$	96.00±0.06	97.60±0.06	0.79±0.08
	V12	Cross Val.	93.50±0.07	94.06±0.43	$5.38 {\pm} 0.86$	95.67±0.04	$95.89 \pm 0.14$	$3.89 \pm 0.27$	$96.68 \pm 0.12$	$97.09 \pm 0.14$	$2.49 \pm 0.32$	$97.10 \pm 0.13$	$97.73 \pm 0.14$	$1.64 \pm 0.22$	$96.00 \pm 0.06$	$97.58 \pm 0.05$	$0.83 \pm 0.09$
2.37 < n < 2.50	Vss.new	Cross Val.	$93.51 \pm 0.05$	$89.66 \pm 0.75$	$14.11 \pm 1.42$	$95.68 \pm 0.03$	$91.58 \pm 0.37$	$12.42 \pm 0.72$	$96.70 \pm 0.01$	$93.10 \pm 0.39$	$10.43 \pm 0.76$	$97.13 \pm 0.02$	$93.45 \pm 0.63$	$10.15 \pm 1.22$	$96.01 \pm 0.01$	$94.13 \pm 0.37$	$7.73 \pm 0.73$
	V21.new	Cross Val.	93.49±0.07	94.01±0.34	5.47±0.68	95.68±0.06	95.98±0.14	$3.72\pm0.26$	96.68±0.13	97.12±0.13	$2.43\pm0.27$	97.12±0.13	97.77±0.10	$1.57 \pm 0.20$	$96.03 \pm 0.14$	97.59±0.10	$0.83 \pm 0.10$
	Vss5var	Cross Val.	93.51±0.04	88.60±0.53	$16.18 \pm 1.02$	95.70±0.01	89.94±0.30	$15.63 \pm 0.59$	96.70±0.02	90.81±1.30	14.88±2.49	97.12±0.04	91.78±0.74	$13.40 \pm 1.44$	$96.01 \pm 0.01$	91.68±0.52	$12.54 \pm 1.02$
	Vss4var	Cross Val.	93.50±0.05	85.60±0.97	$21.94 \pm 1.86$	95.68±0.02	87.35±0.79	$20.59 \pm 1.50$	96.70±0.02	88.07±0.77	$20.15 \pm 1.47$	97.12±0.03	88.58±0.70	$19.56 \pm 1.34$	96.00±0.00	88.22±0.99	$19.24 \pm 1.90$
	V22	Cross Val.	$93.50\pm0.20$	93.94±0.30	$5.62 \pm 0.68$	$95.70\pm0.04$	$95.98 \pm 0.11$	$3.74 \pm 0.22$	96.73±0.17	97.14±0.21	$2.44 \pm 0.33$	97.11±0.17	97.75±0.14	$1.61 \pm 0.21$	$96.01 \pm 0.05$	$97.59 \pm 0.05$	$0.82 \pm 0.10$

Fonte: O autor, 2024.

Tabela 8 -	- Tabela de probabilidade de detecção que apresenta os valores de $P_D$ (verde), $SP \in P_F$ ( $F_R$ ) (falso alarme ou eficiência de background) para	ı cada
	região do espaço de fase com os melhores modelos selecionados pelo $SP_{max}$ para o ponto de operação very loose	

Tabela 8 -	Tabela de probabilidade de detecção que apresenta os valores de $P_D$ (verde), $SP \in P_F(F_R)$ (falso alarme ou eficiência de <i>background</i> ) para cada
	região do espaço de fase com os melhores modelos selecionados pelo $SP_{max}$ para o ponto de operação very losse

		kinematic region		$15 < E_T[GeV] < 20$	)		$20 < E_T[GeV] < 30$	1		$30 < E_T[GeV] < 40$	)		$40 < E_T[GeV] < 50$	1		$E_T[GeV] > 50$	
Det. Region	Method	Type	$P_D[\%]$	SP[%]	$F_R[\%]$	$P_D[\%]$	SP[%]	$F_R[\%]$	$P_D[\%]$	SP[%]	$F_R[\%]$	$P_D[\%]$	SP[%]	$F_R[\%]$	$P_D[\%]$	SP[%]	$F_R[\%]$
	Cut-Based (2017)	Reference	98.85	90.52	17.45	99.50	83.61	30.88	99.83	81.87	34.30	99.94	82.45	33.36	99.98	38.56	92.36
	V8	Cross Val.	98.85±0.00	$97.53 \pm 0.10$	$3.79 \pm 0.19$	99.50±0.00	98.37±0.06	$2.75\pm0.11$	99.83±0.00	98.93±0.05	$1.96 {\pm} 0.10$	99.94±0.00	$98.98 \pm 0.05$	$1.98 {\pm} 0.11$	$99.98 \pm 0.00$	$99.14 \pm 0.10$	$1.70 \pm 0.20$
	V12	Cross Val.	98.85±0.00	97.43±0.10	3.98±0.20	99.50±0.00	98.29±0.08	$2.90 \pm 0.16$	99.83±0.00	98.85±0.06	$2.12 \pm 0.13$	99.94±0.00	98.90±0.08	$2.13 \pm 0.15$	$99.98 \pm 0.00$	$99.14 \pm 0.14$	$1.70 \pm 0.27$
0.00 < - < 0.90	Vss.new	Cross Val.	$98.86 {\pm} 0.01$	96.14±0.12	$6.54 \pm 0.24$	99.50±0.00	96.48±0.18	$6.49 \pm 0.35$	99.83±0.00	96.54±0.27	$6.70 \pm 0.53$	99.94±0.00	96.37±0.34	$7.13 {\pm} 0.67$	99.98±0.00	95.79±1.29	$8.31 \pm 2.52$
$0.00 < \eta < 0.00$	V21.new	Cross Val.	98.85±0.00	$97.98 \pm 0.10$	$2.89 \pm 0.20$	99.50±0.00	98.68±0.05	$2.13 \pm 0.09$	99.83±0.00	99.07±0.05	$1.68 {\pm} 0.10$	99.94±0.00	$99.10 \pm 0.14$	$1.73 \pm 0.27$	$99.98 \pm 0.00$	$99.39 \pm 0.06$	$1.19 \pm 0.12$
	Vss5var	Cross Val.	98.85±0.00	95.83±0.09	$7.16 {\pm} 0.18$	99.50±0.00	$96.18 \pm 0.16$	$7.09 \pm 0.31$	99.83±0.00	95.91±0.36	$7.93 \pm 0.71$	99.94±0.00	95.84±0.39	$8.19 {\pm} 0.77$	99.98±0.00	$94.56 \pm 1.68$	$10.70 \pm 3.27$
	Vss4var	Cross Val.	98.85±0.00	94.35±0.19	$10.04 {\pm} 0.36$	99.50±0.00	$95.09 \pm 0.13$	$9.21 \pm 0.26$	99.83±0.00	95.44±0.19	$8.86 {\pm} 0.36$	99.94±0.00	95.04±0.22	9.75±0.43	$99.98 \pm 0.00$	91.34±1.27	$16.90 {\pm} 2.40$
	V22	Cross Val.	98.85±0.00	$97.93 \pm 0.11$	$2.99 {\pm} 0.22$	99.50±0.00	$98.65 \pm 0.05$	$2.20 \pm 0.09$	99.83±0.00	99.06±0.06	$1.71 {\pm} 0.11$	99.94±0.00	$99.12 \pm 0.05$	$1.70 {\pm} 0.09$	$99.98 {\pm} 0.00$	99.37±0.05	$1.23 \pm 0.10$
	Cut-Based (2017)	Reference	98.78	84.08	29.43	99.62	74.51	46.93	99.91	70.93	53.03	99.97	70.79	53.29	99.93	36.74	93.56
	V8	Cross Val.	98.78±0.00	96.47±0.14	5.82±0.29	99.62±0.00	97.33±0.08	4.93±0.16	$99.91 {\pm} 0.00$	97.91±0.11	$4.07 \pm 0.21$	99.97±0.00	97.89±0.14	4.17±0.28	99.93±0.00	$98.91 \pm 0.04$	$2.10 \pm 0.07$
	V12	Cross Val.	98.78±0.00	96.26±0.12	6.23±0.24	99.62±0.00	$97.17 \pm 0.10$	$5.25 \pm 0.19$	$99.91 {\pm} 0.00$	$97.77 \pm 0.11$	4.33±0.22	99.97±0.00	$97.82 \pm 0.10$	$4.32 \pm 0.21$	99.93±0.00	98.90±0.06	$2.11 \pm 0.12$
0.00 4 4 1.27	Vss.new	Cross Val.	98.78±0.00	95.70±0.13	7.33±0.25	99.62±0.00	96.00±0.14	7.54±0.28	$99.91 {\pm} 0.00$	96.18±0.11	7.47±0.22	99.97±0.00	96.01±0.27	$7.87 \pm 0.53$	99.93±0.00	97.81±0.35	4.28±0.70
$0.80 < \eta < 1.57$	V21.new	Cross Val.	98.78±0.00	$97.16 {\pm} 0.07$	$4.44 \pm 0.13$	99.62±0.00	97.86±0.04	3.89±0.08	$99.91 \pm 0.00$	98.32±0.08	$3.25 \pm 0.15$	99.97±0.00	$98.35 \pm 0.11$	$3.26 \pm 0.22$	99.93±0.00	99.08±0.05	$1.76 {\pm} 0.11$
	Vss5var	Cross Val.	98.78±0.00	$95.12 \pm 0.18$	8.47±0.36	99.62±0.00	$95.26 \pm 0.13$	$9.01 \pm 0.26$	$99.91 {\pm} 0.00$	95.13±0.17	$9.53 \pm 0.33$	99.97±0.00	94.78±0.25	$10.27 \pm 0.50$	99.93±0.00	96.64±0.32	$6.60 \pm 0.62$
	Vss4var	Cross Val.	98.78±0.00	93.06±0.34	$12.49 \pm 0.67$	99.62±0.00	93.90±0.17	$11.65 \pm 0.32$	$99.91 {\pm} 0.00$	94.35±0.19	$11.04 {\pm} 0.36$	99.97±0.00	94.02±0.38	$11.75 \pm 0.74$	99.93±0.00	95.03±0.41	9.74±0.80
	V22	Cross Val.	98.78±0.00	97.03±0.09	$4.71 \pm 0.17$	99.62±0.00	$97.79 \pm 0.06$	$4.03 \pm 0.12$	$99.91 {\pm} 0.00$	98.29±0.08	$3.30 {\pm} 0.15$	99.97±0.00	98.27±0.06	$3.41 \pm 0.12$	99.93±0.00	99.07±0.04	$1.78 {\pm} 0.09$
	Cut-Based (2017)	Reference	97.59	68.96	54.65	96.69	79.71	35.63	97.96	84.41	28.13	97.88	85.60	25.86	98.60	42.92	88.62
	V8	Cross Val.	97.60±0.00	$89.78 \pm 1.18$	$17.70 \pm 2.24$	96.68±0.01	$95.94 \pm 0.19$	4.80±0.39	97.96±0.02	97.40±0.13	$3.16 \pm 0.25$	97.86±0.07	97.80±0.12	$2.26 \pm 0.21$	$98.61 \pm 0.00$	$98.59 \pm 0.08$	$1.43 \pm 0.16$
	V12	Cross Val.	$97.59 \pm 0.01$	89.30±1.30	$18.62 \pm 2.47$	96.69±0.03	95.52±0.22	$5.64 \pm 0.44$	97.97±0.02	97.08±0.16	3.80±0.34	97.89±0.03	97.55±0.13	$2.79 \pm 0.25$	98.60±0.00	98.53±0.18	$1.55 \pm 0.35$
127 < n < 1 54	Vss.new	Cross Val.	$97.59 \pm 0.01$	64.54±2.29	$61.51 \pm 3.45$	96.69±0.00	$79.29 \pm 1.63$	$36.36 \pm 2.91$	$97.96 {\pm} 0.01$	$82.38 \pm 1.63$	$31.83 \pm 2.97$	97.88±0.01	84.33±1.23	$28.21 \pm 2.28$	$98.61 \pm 0.00$	85.03±2.86	$27.49 \pm 5.21$
$1.51 < \eta < 1.54$	V21.new	Cross Val.	$97.59 {\pm} 0.01$	$89.92 \pm 1.52$	$17.43 {\pm} 2.91$	96.69±0.02	95.73±0.21	5.23±0.43	97.97±0.03	97.27±0.21	3.43±0.43	97.89±0.04	97.65±0.13	$2.59 \pm 0.27$	$98.60 {\pm} 0.00$	$98.64 \pm 0.05$	$1.32 {\pm} 0.09$
	Vss5var	Cross Val.	$97.59 \pm 0.01$	$62.99 \pm 2.36$	63.85±3.47	96.69±0.00	$71.71 \pm 1.31$	$49.50 \pm 2.17$	97.96±0.00	$73.44 \pm 2.16$	$47.49 \pm 3.59$	97.88±0.00	77.46±2.09	40.53±3.58	$98.61 {\pm} 0.00$	$74.37 \pm 4.12$	46.29±6.89
	Vss4var	Cross Val.	$97.59 {\pm} 0.01$	$58.47 \pm 1.17$	$70.37{\pm}1.61$	$96.69 {\pm} 0.01$	$64.90 \pm 1.12$	60.45±1.73	97.96±0.00	$69.65 \pm 1.19$	$53.77 \pm 1.93$	97.88±0.01	$74.15 \pm 1.46$	46.24±2.47	98.70±0.29	$67.64 \pm 7.95$	$56.79 \pm 11.13$
	V22	Cross Val.	$97.59 \pm 0.01$	89.43±1.28	$18.37 {\pm} 2.43$	96.70±0.01	$95.68 \pm 0.21$	$5.33 \pm 0.42$	97.95±0.03	97.21±0.26	$3.52{\pm}0.51$	97.90±0.04	$97.62 \pm 0.12$	$2.66 {\pm} 0.24$	$98.61 {\pm} 0.00$	98.63±0.07	$1.35 {\pm} 0.13$
	Cut-Based (2017)	Reference	98.25	83.45	30.14	99.57	81.02	35.62	99.91	80.42	36.96	99.97	80.55	36.77	99.98	41.60	90.08
	V8	Cross Val.	98.26±0.00	96.46±0.08	$5.32 \pm 0.15$	99.57±0.00	$97.01 \pm 0.16$	$5.52 \pm 0.31$	99.92±0.00	97.43±0.08	$5.03 {\pm} 0.15$	99.97±0.00	$97.76 \pm 0.13$	4.43±0.25	$99.98 {\pm} 0.00$	$96.15 \pm 0.78$	$7.60 \pm 1.53$
	V12	Cross Val.	98.26±0.00	96.47±0.22	$5.30 \pm 0.44$	99.57±0.00	$97.13 \pm 0.21$	$5.28 \pm 0.41$	$99.91 {\pm} 0.00$	$97.56 \pm 0.21$	$4.77 \pm 0.41$	99.97±0.00	$97.82 \pm 0.14$	$4.31 \pm 0.28$	$99.98 {\pm} 0.00$	$96.71 \pm 0.84$	$6.50 \pm 1.64$
154 < n < 2.27	Vss.new	Cross Val.	98.25±0.00	$93.98 \pm 0.11$	$10.19 \pm 0.22$	99.57±0.00	94.04±0.23	$11.33 \pm 0.44$	$99.91 \pm 0.00$	94.30±0.30	$11.15 {\pm} 0.58$	99.97±0.00	$94.15 \pm 0.17$	$11.49 \pm 0.32$	$99.98 \pm 0.00$	90.33±1.23	$18.82 \pm 2.33$
1.54 < 1 < 2.51	V21.new	Cross Val.	98.25±0.00	96.84±0.08	$4.57 \pm 0.15$	99.57±0.00	$97.43 \pm 0.11$	$4.69 \pm 0.21$	$99.91 {\pm} 0.00$	$97.75 \pm 0.12$	$4.38 \pm 0.23$	99.97±0.00	$97.97 \pm 0.13$	$4.00 \pm 0.25$	$99.98 {\pm} 0.00$	96.93±0.73	$6.08 \pm 1.44$
	Vss5var	Cross Val.	98.26±0.00	92.79±0.17	$12.52 \pm 0.33$	99.57±0.00	$92.81 \pm 0.23$	$13.72 \pm 0.44$	$99.91 {\pm} 0.00$	$92.91 \pm 0.43$	$13.83 \pm 0.83$	99.97±0.00	93.22±0.36	$13.28 {\pm} 0.69$	99.98±0.00	88.24±2.39	22.73±4.42
	Vss4var	Cross Val.	98.26±0.00	$91.22 \pm 0.30$	$15.55 \pm 0.58$	99.57±0.00	$91.18 \pm 0.38$	$16.84 \pm 0.72$	$99.91 \pm 0.00$	$91.62 \pm 0.29$	$16.31 {\pm} 0.56$	99.97±0.00	$91.47 \pm 0.44$	$16.65 \pm 0.83$	$99.98 \pm 0.00$	$80.23 \pm 2.76$	$37.29 \pm 4.86$
	V22	Cross Val.	$98.26 \pm 0.01$	$96.84 \pm 0.09$	$4.57 \pm 0.17$	99.57±0.00	$97.39 \pm 0.09$	$4.76 \pm 0.18$	$99.91 {\pm} 0.00$	$97.71 \pm 0.11$	$4.48 \pm 0.22$	99.97±0.00	$97.91 \pm 0.15$	$4.13 \pm 0.31$	$99.98 \pm 0.00$	$96.59 \pm 0.49$	6.74±0.96
	Cut-Based (2017)	Reference	93.55	59.08	67.31	95.73	69.30	52.82	96.71	73.78	46.03	97.12	73.79	46.31	96.01	50.46	79.95
	V8	Cross Val.	93.45±0.26	94.20±0.39	$5.06 \pm 0.88$	95.77±0.04	$96.04 \pm 0.16$	$3.69 \pm 0.28$	$96.69 \pm 0.13$	$97.17 \pm 0.15$	$2.34{\pm}0.34$	96.99±0.24	97.72±0.13	$1.54 {\pm} 0.18$	96.00±0.06	97.60±0.06	$0.79 \pm 0.08$
	V12	Cross Val.	$93.51 \pm 0.08$	$94.05 \pm 0.44$	$5.41 \pm 0.87$	95.72±0.05	$95.91 \pm 0.14$	$3.91 \pm 0.27$	$96.68 \pm 0.12$	$97.09 \pm 0.14$	$2.49 \pm 0.32$	97.10±0.13	$97.73 \pm 0.14$	$1.64 \pm 0.22$	$96.00 \pm 0.06$	$97.58 \pm 0.05$	$0.83 \pm 0.09$
237 < n < 250	Vss.new	Cross Val.	93.55±0.05	89.63±0.74	$14.20 \pm 1.45$	95.74±0.02	$91.58 \pm 0.36$	$12.48 \pm 0.71$	$96.71 \pm 0.01$	93.09±0.39	$10.45 \pm 0.77$	97.13±0.02	93.45±0.63	$10.15 \pm 1.22$	$96.01 {\pm} 0.01$	$94.13 \pm 0.37$	7.74±0.73
2.51 \ 11 \ 2.50	V21.new	Cross Val.	93.53±0.08	94.01±0.34	$5.51 \pm 0.73$	95.75±0.06	$96.00 \pm 0.13$	$3.74 \pm 0.26$	$96.68 \pm 0.13$	$97.12 \pm 0.13$	$2.43 \pm 0.27$	97.12±0.13	$97.77 \pm 0.10$	$1.57 \pm 0.20$	96.03±0.14	$97.59 \pm 0.10$	$0.83 {\pm} 0.10$
	Vss5var	Cross Val.	$93.55 \pm 0.02$	88.58±0.56	$16.26 \pm 1.10$	$95.74 \pm 0.01$	$89.93 \pm 0.29$	$15.71 \pm 0.57$	96.71±0.02	$90.81 \pm 1.30$	$14.90 {\pm} 2.49$	97.12±0.04	$91.78 \pm 0.74$	$13.40 {\pm} 1.44$	$96.01 \pm 0.01$	$91.68 \pm 0.52$	$12.54 \pm 1.02$
	Vss4var	Cross Val.	93.57±0.04	85.61±0.97	$21.98 {\pm} 1.84$	95.73±0.02	87.35±0.80	$20.65 \pm 1.52$	$96.71 {\pm} 0.01$	88.07±0.77	$20.17 \pm 1.47$	97.12±0.03	88.58±0.70	$19.56 {\pm} 1.34$	$96.01 {\pm} 0.01$	$88.21 \pm 0.99$	$19.25 \pm 1.89$
	V22	Cross Val.	93.53±0.20	$93.94{\pm}0.31$	$5.65 \pm 0.72$	95.73±0.03	$95.98 \pm 0.12$	$3.77 \pm 0.22$	96.73±0.17	$97.14 \pm 0.21$	$2.44{\pm}0.33$	$97.11 \pm 0.17$	$97.75 \pm 0.14$	$1.61 {\pm} 0.21$	$96.01 \pm 0.05$	$97.59 \pm 0.05$	$0.82{\pm}0.10$

Fonte: O autor, 2024.

## **APÊNDICE B** – Curvas de eficiência

Neste anexo, apresentamos outras curvas de eficiência. Não estão apresentadas nesta seção as curvas referentes à eficiência dos dados reais que foram utilizados para o treino, pois apresentam resultados muito semelhantes entre os modelos devido a escolha do  $P_D$  de referência ser o mesmo para todas. Dessa forma, será apresentada a taxa de falso alarme para eventos reais primeiro, e depois a eficiência para eventos simulados.

Os gráficos das figuras 55, 56 e 57 apresentam a distribuição de eficiência em  $E_T$  para jatos (*background*) para as três cadeias (e26\_lhtight, e60\_lhmedium e e140\_lhloose) em que se pode destacar que todos os modelos com anéis (V8, V12, V21, V22 e V21New) apresentam melhores resultados que os modelos sem anéis (Vss, Vssoutf3, Vssoutf3 e VssNew). Na cadeia e26\_lhtight, abaixo de 50 GeV, os modelos de fusão (V21, V22, V21New) e o *NeuralRinger* com 100 anéis (V8) apresentam melhores resultados (menos no HLT onde todas as eficiências estão muito próximas). A cadeia e140\_lhloose, apresenta melhores resultados para o *NeuralRinger* com 100 anéis (V8) seguido dos modelos de fusão (V21, V22, V21New), vindo o *NeuralRinger* com 50 anéis e por último os modelos sem anéis (Vss, Vssoutf3, Vssoutf3 e VssNew).

As figuras 58, 59 e 60 apresentam os gráficos referentes a distribuição de eficiência em  $p_T$  para jatos (*background*) para as três cadeias (e26\_lhtight, e60\_lhmedium e e140\_lhloose) em que se pode destacar que todos os modelos com anéis (V8, V12, V21, V22 e V21New) apresentam melhores resultados que os modelos sem anéis (Vss, Vssoutf3, Vssoutfs e VssNew). Nas cadeias e26\_lhtight e e60\_lhmedium, as melhores eficiências são dos modelos de fusão (V21, V22, V21New) e o *NeuralRinger* com 100 anéis (V8), pois para altos momentos transversos, o *NeuralRinger* com 50 anéis (V12) aumenta sua taxa de *background* enquanto na cadeia e140\_lhloose, ela apresenta resultados melhores para o *NeuralRinger* com 100 anéis (V8).

Para o falso alarme, para a distribuiçao de  $\eta$  está apresentada nas figuras 61, 62, 63 e 64 para as quatro cadeias (e24\_lhtight, e26\_lhtight, e60\_lhmedium e e140\_lhloose) onde se pode destacar que todos os modelos com anéis (V8, V12, V21, V22 e V21New) apresentam melhores resultados que os modelos sem anéis (Vss, Vssoutf3, Vssoutf3 e VssNew). Em todas, os modelos com os anéis estão com as eficiências bem próximas, mas na cadeia e140\_lhloose, há resultados melhores para o *NeuralRinger* com 100 anéis (V8) a partir de  $|\eta| > 1, 5$ .

Nas quatro cadeias e24\_lhtight, e26\_lhtight, e60\_lhmedium e e140\_lhloose para os gráficos referentes ao falso alarme da distribuição  $\mu$  (empilhamento, *pileup*) presentes nas figuras 65, 66, 67 e 68 pode-se destacar que todos os modelos com anéis (V8, V12, V21, V22 e V21New) apresentam melhores eficiências que os modelos sem anéis (Vss, Vssoutf3, Vssoutfs e VssNew). Em todas essas figuras, os modelos com os anéis (V8, V12,



Figura 55 - Eficiência de identificação de jatos (falso alarme) como elétrons relativa a  $E_T$  para e26 *lhtight* 

Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.

V21, V22 e V21New) estão com eficiências bem próximas, mas na cadeia e140\_lhloose apresenta resultados melhores para o NeuralRinger com 100 anéis (V8).

Os próximos gráficos serão referentes a avaliação dos modelos utilizando eventos simulados de Monte Carlo de 2016 que apresentam amostras de elétrons *Boosted*. Para as três cadeias: e26\_lhtight, e60\_lhmedium e e140\_lhloose, os gráficos de eficiência da distribuição de  $E_T$  para eventos simulados (*boosted*) estão apresentadas nas figuras 69, 70 e 71. Em todas essas figuras, os modelos têm eficiências bem próximas, com o *Neural-Ringer* com 100 anéis (V8) e a nova fusão de 6 variáveis (V21New) apresenta os piores resultados e o modelo de 4 variáveis de *shower shape* (Vssoutfs) os melhores resultados.

A eficiência da distribuição de  $p_T$  para as cadeias e26\_lhtight, e60\_lhmedium e e140\_lhloose está apresentada nos gráficos das figuras 72, 73 e 74. Em todas essas figuras, o *NeuralRinger* com 100 anéis (V8) tem os piores resultados quando não tem eficiências próximas dos outros modelos e o modelo de 4 variáveis de *shower shape* (Vssoutfs) apresenta os melhores resultados. Os modelos de fusão V21 e V22 juntamente



Figura 56 - Eficiência de identificação de jatos (falso alarme) como elétrons relativa a  $E_T$  para e60 *lhmedium* 

Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.

com o *NeuralRinger* de 50 anéis (V12) ficam com eficiências muito próximas entre si. Na cadeia e140\_lhloose, todos os modelos apresentam eficiências muito próximas, menos o *NeuralRinger* com 100 anéis (V8) que possui eficiências menores.

As figuras 75, 76 e 77 apresentam os gráficos referentes a eficiência da distribuição de  $\Delta R$  para as cadeias e26\_lhtight, e60\_lhmedium e e140\_lhloose. O resultado das eficiências é bem similar aos de  $p_T$ , o NeuralRinger com 100 anéis (V8) tem os piores resultados enquanto o modelo de 4 variáveis de shower shape (Vssoutfs) tem os melhores resultados e os modelos de fusão V21 e V22 juntamente com o NeuralRinger de 50 anéis (V12) apresentam eficiências muito próximas entre si.

Nas cadeias e24\_lhtight, e26\_lhtight, e60\_lhmedium e e140\_lhloose, a eficiência da distribuição de  $\eta$  para eventos simulados (*boosted*) está apresentada nos gráficos das figuras 78, 79, 80 e 81. O resultado das eficiênicas é bem similar aos anteriores, o *NeuralRinger* com 100 anéis (V8) com os piores resultados enquanto o modelo de 4 variáveis de *shower shape* (Vssoutfs) com os melhores, porém nas etapas rápidas, menos na



Figura 57 - Eficiência de identificação de jatos (falso alarme) como elétrons relativa a  $E_T$  para e140 *lhloose* 

Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.

cadeia e140\_lhloose, a fusão de 4 variáveis (V22) apresenta melhores resultados quando  $||\eta| < 1,5$  e quando  $|\eta| = 1.5$ , o *NeuralRinger* de 50 anéis (V12) é o melhor. Na cadeia e140\_lhloose, todos os modelos têm eficiências bem próximas menos o *NeuralRinger* com 100 anéis (V8) que está com menores eficiências e quando  $|\eta| = 1.5$ , os modelos de fusão V21 e V22 e o *NeuralRinger* com 50 anéis (V12) tem suas eficiências bem próximas.

Os gráficos referentes a distribuição de  $\mu$  avaliados nos dados simulados não foram introduzidos por serem bastante similares e somente apresentarem uma diferença do *NeuralRinger* com 100 anéis (V8) e do novo modelo de fusão, V21New, com eficiências menores nos três primeiros *bins*.

Figura 58 - Eficiência de identificação de jatos (falso alarme) como elétrons relativa a $p_T$  para e26 lhtight



Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo. Fonte: O autor, 2024.

Figura 59 - Eficiência de identificação de jatos (falso alarme) como elétrons relativa a $p_T$ para e<br/>60 lhmedium



Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.

Figura 60 - Eficiência de identificação de jatos (falso alarme) como elétrons relativa a  $p_T$  para e140 lhloose



Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.

Figura 61 - Eficiência de identificação de jatos (falso alarme) como elétrons relativa a $\eta$ para e24 lhtight



Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.

Figura 62 - Eficiência de identificação de jatos (falso alarme) como elétrons relativa a $\eta$ para e26 lhtight



Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.

Figura 63 - Eficiência de identificação de jatos (falso alarme) como elétrons relativa a $\eta$ para e<br/>60 lhmedium



Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.

Figura 64 - Eficiência de identificação de jatos (falso alarme) como elétrons relativa a $\eta$ para el<br/>40 lhloose



Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.



Figura 65 - Eficiência de identificação de jatos (falso alarme) como elétrons relativa a $\mu$ para e24 lhtight

Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.

20.09 2Calo\_e26\_Ihtight\_nod0 2.00 40.08 2\_e26\_Ihtight\_nod0 gerV8 - E (L2): 0.81 % gerV12 - E (L2): 0.87 gerV21 - E<sup>n</sup> (L2): 0.84 gerV23 - E<sup>n</sup> (L2): 0.84 ₩ 0.07 1.00 % 10): 2.97 % a 30.06 a 20.06 (L2): 2.89 % ⊢ 0.05 ⊢ 0.05 0.04 0.04 0.03 0.03 0.02 0.02 0.01 0.01 0E 10 0E 10 40 30 40 20 30 50 20 50 60 -----70 < μ > 60 (a) (b) ×10<sup>-3</sup> ELT\_e26\_Ihtight\_nod0 0.08 FCalo\_e26\_Ihtight\_nod0 10.07 : 0.00 % (HLT): 0.00 % (HLT): 0.00 % -190.06 190.05 alo): 0.68 % EFCalo): 2.68 % EFCalo): 0.66 % Trigger 60.03 % .00 % .00 % 0.04 0.02 0.03 0.02 0.01 0.01 0 0E 10 40 20 30 50 60 10 30 40 50 60 20 70 70 < µ > < µ > (c) (d)

Figura 66 - Eficiência de identificação de jatos (falso alarme) como elétrons relativa a $\mu$ para e26 lhtight

Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.



Figura 67 - Eficiência de identificação de jatos (falso alarme) como elétrons relativa a $\mu$ para e<br/>60 lhmedium

Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.



Figura 68 - Eficiência de identificação de jatos (falso alarme) como elétrons relativa a $\mu$ para e140 lhloose

Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.

Figura 69 - Eficiência de identificação de elétrons (probabilidade de detecção) relativa a  $E_T$ eventos simulados (elétrons *Boosted*) para e26 *lhtight* 



Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.

Figura 70 - Eficiência de identificação de elétrons (probabilidade de detecção) relativa a  $E_T$ eventos simulados (elétrons *Boosted*) para e60 *lhmedium* 



Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.

Figura 71 - Eficiência de identificação de elétrons (probabilidade de detecção) relativa a  $E_T$  eventos simulados (elétrons *Boosted*) para e140 *lhloose* 



Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.

Figura 72 - Eficiência de identificação de elétrons (probabilidade de detecção) relativa a  $p_T$ eventos simulados (elétrons *Boosted*) para e26 *lhtight* 



Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.

Figura 73 - Eficiência de identificação de elétrons (probabilidade de detecção) relativa a  $p_T$ eventos simulados (elétrons *Boosted*) para e60 *lhmedium* 



Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.

Figura 74 - Eficiência de identificação de elétrons (probabilidade de detecção) relativa a  $p_T$  eventos simulados (elétrons *Boosted*) para e140 *lhloose* 



Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.

Figura 75 - Eficiência de identificação de elétrons (probabilidade de detecção) relativa a  $\Delta R$  eventos simulados (elétrons Boosted) para e26 lhtight



Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.
Figura 76 - Eficiência de identificação de elétrons (probabilidade de detecção) relativa a $\Delta R$  eventos simulados (elétrons Boosted) para e<br/>60 lhmedium



Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.

Figura 77 - Eficiência de identificação de elétrons (probabilidade de detecção) relativa a  $\Delta R$  eventos simulados (elétrons Boosted) para e<br/>140 lhloose



Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.

Figura 78 - Eficiência de identificação de elétrons (probabilidade de detecção) relativa a $\eta$ eventos simulados (elétrons Boosted) para e24 lh<br/>tight



Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.

Figura 79 - Eficiência de identificação de elétrons (probabilidade de detecção) relativa a  $\eta$  eventos simulados (elétrons *Boosted*) para e26 *lhtight* 



Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.

Figura 80 - Eficiência de identificação de elétrons (probabilidade de detecção) relativa a $\eta$ eventos simulados (elétrons Boosted) para e<br/>60 lhmedium



Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.

Figura 81 - Eficiência de identificação de elétrons (probabilidade de detecção) relativa a $\eta$ eventos simulados (elétrons Boosted) para e<br/>140 lhloose



Legenda: (a) *FastCalo*, (b) *Fastelectron*, (c) HLTCalo, (d) HLT. Fonte: O autor, 2024.