

Avaliação da Contribuição Longitudinal de um Calorímetro Finamente Segmentado para a Filtragem Online Realizada por um Ensemble de Redes Neurais em Ambiente de Alta Taxa de Eventos

Micael Veríssimo de Araújo*,
Carlos Eduardo Covas Costa,
João Victor da Fonseca Pinto,
José Manoel de Seixas
Laboratório de Processamento de Sinais
COPPE/UFRJ
Rio de Janeiro, Brasil.
Email: *micael.verissimo@lps.ufrj.br

Werner Spolidoro Freund
LPNHE, CNRS/IN2P3
Sorbonne Université
Paris, França.

Marcia Begalli
Instituto de Física
UERJ,
Rio de Janeiro, Brasil

Resumo—Em grandes experimentos, a tomada de dados pode ser feita por uma grande quantidade de canais de leitura, que são empregados de modo a obter a informação de interesse registrada por uma grande quantidade de sensores. Se houver o interesse por eventos raros, o emprego de técnicas multivariadas e um sistema de filtragem que possa eliminar os eventos não interessantes de modo *online* pode vir a ser considerada para manter estável a tomada de dados. No experimento LHC (Large Hadron Collider) de colisão de partículas (prótons) de altas energias (13 TeV, no centro de massa), o sistema *NeuralRinger* utiliza um conjunto de redes neurais do tipo perceptron de múltiplas camadas, para realizar a filtragem *online* de eventos no ATLAS, o maior experimento do LHC, buscando detectar elétrons, cuja presença é indicador para vários processos de física nova que se deseja observar experimentalmente. O *NeuralRinger* utiliza-se das informações provenientes do sistema de calorímetros (equipamentos responsáveis por medir a energia das partículas) para alimentar as redes neurais e, assim, tomar a decisão de filtragem. Todavia, com o aumento da quantidade de colisões no LHC, e o fato de que partes do sistema de calorimetria necessitam de maior tempo de leitura durante a tomada de dados, uma estratégia de filtragem que possa contornar tais limitações é mandatória para alguns canais de interesse. Este trabalho avalia uma extensão do *NeuralRinger* para atuar na detecção de elétrons até 15 GeV e que não utiliza toda a segmentação longitudinal disponível nos calorímetros do ATLAS. Resultados indicam que, apesar de uma pequena perda de eficiência, esta opção pode vir a ser considerada quando for retomada a coleta de dados do ATLAS, em 2021.

Keywords—Redes Neurais; Processamento Online; Calorimetria

I. INTRODUÇÃO

Hoje em dia, é comum que, em uma aquisição dos dados para uma determinada aplicação, a informação de interesse seja registrada por uma grande quantidade de canais de leitura. Quando se trata de um sistema de filtragem *online*, o uso de

tantos canais pode resultar no aumento da latência do sistema, o que, conseqüentemente, poderá acarretar na perda de eventos de interesse. Desta forma, o emprego de uma técnica que utilize apenas parte da informação disponível e que seja efetiva na tarefa de filtragem torna-se uma potencial solução.

Neste contexto, podemos destacar o experimento ATLAS (sigla para *A Toroidal LHC Apparatus*) [3] situado no LHC (*Large Hadron Collider*) [8], o maior colisionador de partículas do mundo, possuindo 27 km de circunferência. Com as colisões geradas pelo LHC, foi descoberto o bóson de Higgs em 2012, o que laureou os físicos P. W. Higgs e F. Englert com o prêmio Nobel de Física [14].

O ATLAS¹ é o maior dos experimentos do LHC, medindo 44 metros de comprimento e 25 metros de altura. Ele é um experimento de âmbito geral, ou seja, procura estudar todos os processos físicos gerados pelas colisões próton-próton do LHC [8]. O ATLAS possui um formato cilíndrico e é dividido em três sub-detectores: o Detector de Traços (ID), que tem o objetivo de medir a trajetória das partículas eletricamente carregadas; os calorímetros², que atuam na medição da energia das partículas [22]; e a câmara de múons, especificamente projetada para detecção destas partículas que,

¹O ATLAS utiliza um sistema de coordenadas tem sua origem no ponto de interação nominal (*Interaction Point* - IP), no centro do detector e a direção do eixo z é paralela à direção do feixe de partículas. O eixo x aponta do IP para o centro da circunferência do LHC e o eixo y é perpendicular ao eixo x , tendo sentido positivo para cima. São utilizadas coordenadas cilíndricas (r, ϕ) , onde ϕ é o ângulo azimutal tomado em relação ao eixo x e definido no plano xy ; θ é o ângulo polar em relação ao eixo z ; e a pseudorapidez (η) é definida em termos do ângulo polar: $\eta = -\ln \tan(\frac{\theta}{2})$

²Todo sistema de calorimetria do ATLAS conta com 7 camadas de amostragem, sendo uma de pré-amostragem, três camadas eletromagnéticas e três camadas hadrônicas.

como os elétrons, também são mensageiras de física interessante no LHC [15]. O ATLAS possui dois calorímetros [17]: o calorímetro Eletromagnético (ECAL), responsável por medir a energia das partículas que interagem por meio da força eletromagnética; e o calorímetro Hadrônico (HCAL), responsável por medir a energia das partículas que interagem por meio da força forte.

As colisões no LHC ocorrem a cada 25 ns, gerando, $\sim 1,7$ MB por evento no ATLAS. O fato do detector possuir uma estrutura altamente segmentada tornaria necessário a aquisição de 70 TB/s [9], o que torna, inviável armazenar toda a informação e imperativo o uso de um sistema de filtragem *online* (*Trigger*) para as assinaturas de interesse.

O sistema de *Trigger* do ATLAS faz uso de reconhecimento de padrões com o objetivo de identificar objetos físicos que sejam de interesse para o ATLAS. Esta filtragem é realizada em dois níveis [19]. No primeiro nível (L1), implementado em *hardware*, a taxa de entrada (40 MHz) é reduzida para 100 kHz. O segundo nível, totalmente implementado em *software*, chamado *High Level Trigger* (HLT), objetiva manter a taxa média de saída em 1,5 kHz, com uma latência média em torno de 200 ms. O HLT é subdividido em duas etapas, a saber, rápida (*fast*) e precisa (*precision*). Na etapa rápida, são empregados sistemas que possuem menor latência, neste caso, o sistema de calorimetria; enquanto que, na etapa precisa, são utilizados algoritmos que possuem maior latência, como por exemplo, algoritmos de processamento de imagem utilizados na identificação da trajetória das partículas carregadas.

Os objetos físicos de interesse deste trabalho são elétrons, neste caso, canais ou cadeias baseadas em elétrons que aplicam um ou mais critérios de seleção a cada etapa de filtragem. Os elétrons são partículas encontradas em diversos processos físicos importantes na física do LHC, a exemplo dos decaimentos do bóson de Higgs [2]. No ATLAS, a identificação de elétrons é baseada principalmente pela informação oriunda do sistema de calorimetria e do ID. Uma vez que são necessários maiores recursos de processamento para tratar as informações do ID (imagem), a filtragem utilizando apenas a informação do sistema de calorimetria permite obter menor latência, possibilitando assim, melhor uso dos recursos *online* disponíveis.

O LHC vem aumentando gradativamente o número de eventos por colisão de feixe de prótons, objetivando coletar mais dados. Este processo é feito através da colimação dos feixes, e isso acaba gerando empilhamento de sinais no detector (*pile-up*) [13]. Com o *pile-up*, há mais informação a ser processada e a decisão se torna mais difícil, dada as distorções dos sinais oriunda da maior ocupação do detector.

Para conter os efeitos do *pile-up*, o ATLAS, no ano de 2017, mudou a estratégia de filtragem de elétrons empregada na etapa rápida do HLT e passou a utilizar um conjunto de redes neurais (*NeuralRinger*) para tomada de decisão [9]. O *NeuralRinger* [9], [21] emprega apenas a informação oriunda do sistema de calorimetria. Esta informação é compactada sob a forma de anéis concêntricos de deposição de energia. Entretanto, o *NeuralRinger* é utilizado apenas para detecção

de elétrons cuja energia transversa (E_T^3) é maior ou igual à 15 GeV, pois abaixo deste patamar é utilizado um conjunto de cortes sequenciais em variáveis extremamente discriminantes. As variáveis utilizadas (definidas abaixo) e sua sequência de corte são: R_η , E_{ratio} , $E_{T,EM}$ e R_{had} .

- R_η (vazamento em η): definida na segunda camada eletromagnética (EM2) como:

$$R_\eta = \frac{E_{3 \times 7}}{E_{7 \times 7}}, \quad (1)$$

onde $E_{m \times n}$ é a energia depositada em uma região de tamanho $m \times n$ células em $\eta \times \phi$ ao redor da célula mais quente da EM2 (com maior energia depositada).

- E_{ratio} : definida como a razão da diferença de energia entre o maior e o segundo maior depósito de energia e a soma dessas energias na primeira camada eletromagnética (EM1).

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

- $E_{T,EM}$ (Energia Transversa Eletromagnética): definida como a energia transversa total que foi depositada ao longo das três camadas do calorímetro eletromagnético (EM1, EM2, EM3), em uma região de tamanho 3×7 células, centrada na célula mais quente da EM2.
- R_{had} (vazamento hadrônico): definida como:

$$R_{had} = \frac{E_T^{had}}{E_T^{EM}}, \quad (3)$$

onde E_T^{had} é a energia transversa medida no HCAL e E_T^{EM} é a energia transversa medida no ECAL.

Este artigo irá apresentar uma extensão do *NeuralRinger* para a região com $E_T < 15$ GeV, avaliando se utilizando apenas parte da informação do sistema de calorimetria (a informação oriunda do calorímetro eletromagnético) é possível manter uma alta eficiência, uma vez que os anéis retêm a informação física principal e o calorímetro eletromagnético amostra elétrons com alta qualidade. Nesta faixa de energia, as flutuações geradas são maiores e a resolução de energia do calorímetro eletromagnético diminui, uma vez que esta resolução é dada pela Eq. 4 [22].

$$\frac{\delta E}{E} \approx \frac{10\%}{\sqrt{E}} \oplus 1\% \quad (4)$$

onde \oplus representa a soma em quadratura.

A restrição do uso apenas da parte eletromagnética é feita devido ao fato das células do calorímetro hadrônico do ATLAS serem grandes [17]; com isso, uma mesma célula acaba sendo requisitada por mais de um evento, aumentando assim o tempo de resposta da mesma.

O artigo é organizado da seguinte forma: a descrição do *NeuralRinger* é feita na Seção II. Na Seção III, será descrita a extensão proposta para o *NeuralRinger* neste trabalho. A discussão dos resultados obtidos é feita na Seção IV seguida das conclusões na Seção V.

³A energia transversa de um objeto com massa m e momento transverso p_T é dada por: $E_T = \sqrt{m^2 + p_T^2}$.

II. NeuralRinger

Os elétrons têm sua energia absorvida nos calorímetros, gerando um chuva de partículas [22]. Estes chuvis são descritos por grandezas físicas que baseiam-se na largura lateral e longitudinal do chuva que foi medido no calorímetro, e esta informação é extremamente importante quando se busca caracterizar tais chuvis. Sabe-se que a energia dos chuvis eletromagnéticos fica contida (em torno de $90 \sim 99\%$) em um cilindro de raio entre 1 e $3,5 R_M$, onde R_M é o raio de Molière⁴ e se alastram por uma região lateralmente mais ampla do calorímetro, conforme se desenvolve longitudinalmente de modo a obter um aspecto cônico.

Uma forma alternativa de se obter as características do chuva é através da construção de anéis concêntricos de deposição de energia [20]. O *NeuralRinger* utiliza tal estratégia e, para cada anel, soma as energias das células que o compõem, ao longo de uma Região de Interesse (*Region of Interest - RoI*), que é selecionada durante o primeiro nível de filtragem. Este processo feito ao longo das camadas de amostragem do sistema de calorimetria do ATLAS permite a caracterização, de maneira compacta, da largura longitudinal dos chuvis (Veja Fig. 1). São construídos um total de 100 anéis ao longo dos calorímetros do ATLAS, conforme visto na Tabela I.

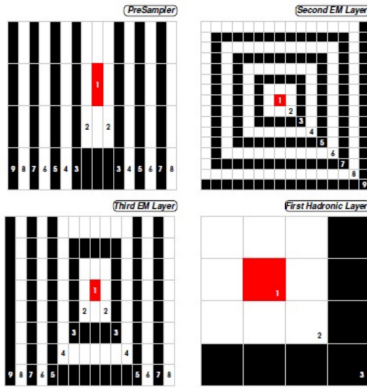


Figura 1. Ilustração da reconstrução dos anéis na ao longo das camadas do calorímetro eletromagnético e a primeira camada do calorímetro hadrônico. Fonte: [21]

Tabela I

NÚMERO DE ANÉIS POR CAMADA DOS CALORÍMETROS. SENDO PS O CALORÍMETRO PRÉ-AMOSTRADOR; EM1,2,3 REFERENTES AS CAMADAS DO CALORÍMETRO ELETROMAGNÉTICO; E HAD1,2,3 REFERENTE AS CAMADAS DO CALORÍMETRO HADRÔNICO.

PS	EM1	EM2	EM3	HAD1	HAD2	HAD3	Total
8	64	8	8	4	4	4	100

Os processos físicos gerados pelas interações dos elétrons no calorímetro sofrem alterações em função da energia; semelhantemente, para manter a informação ao longo do sistema

⁴Por definição, o raio de Molière é o raio do cilindro com eixo coincidindo com o eixo do chuva. Este contém, em média, 90% da deposição de energia do chuva [12].

de calorimetria o mais uniforme possível, o sistema de *Trigger* segmentou a decisão por regiões específicas de E_T e η (posição). Desta forma, o *NeuralRinger*, que hoje atua na etapa rápida do HLT, utiliza 25 redes neurais para a tomada de decisão de filtragem, apenas baseando-se na informação dos 100 anéis [9], [21]. Para cada evento uma rede neural assume a decisão de acordo com o ponto de impacto e a energia estimada.

III. EXTENSÃO PROPOSTA

A extensão proposta neste trabalho visa a operação na região com $E_T < 15$ GeV para a próxima tomada de dados do ATLAS (*Run 3*); hoje, o ATLAS e o LHC estão passando por um período de *upgrades*, retomando a operação em 2021. Nesta região de mais baixa energia, a identificação dos chuvis é degradada devido a baixa resolução de energia dos calorímetros. Também é proposto utilizar apenas parte dos anéis construídos no sistema de calorimetria, excluindo, assim, os anéis oriundos das seções hadrônicas do ATLAS, devido ao seu maior tempo de leitura. Assim, o desenvolvimento dos modelos é feito com base nos 88 anéis da seção eletromagnética.

A construção do *ensemble* que compõe o *NeuralRinger* foi feita dividindo-se o espaço de fase em 3 regiões de E_T , com $4 \leq E_T < 15$ GeV e 5 regiões de η , estas limitadas à $0, 0 \leq |\eta| < 2, 47$, obtendo, assim 15 regiões, conforme descrito na Tabela II

Ajuste do Modelo	
Fronteira das Regiões em E_T [GeV]	
$4 \leq E_T < 7$	
$7 \leq E_T < 10$	
$10 \leq E_T < 15$	
Fronteiras das Regiões em $ \eta $	
$0, 0 \leq \eta < 0, 8$	
$0, 8 \leq \eta < 1, 37$	
$1, 37 \leq \eta < 1, 54$	
$1, 54 \leq \eta < 2, 37$	
$2, 37 \leq \eta < 2, 47$	

Tabela II

FRONTEIRAS PARA AS REGIÕES EM η E E_T EMPREGADAS NO AJUSTE DOS MODELOS PARA O *NeuralRinger* ABAIXO DE 15 GeV. UM TOTAL DE 15 REGIÕES SÃO UTILIZADAS PARA COMPOR O *ensemble* DE REDES NEURAIAS.

Abaixo de 15 GeV, a maior geração de elétrons (sinal) é obtida do decaimento do méson J/Ψ , onde o mesmo decai em um par elétron-pósitron. Assim, para a construção do conjunto de dados de treinamento, foram utilizadas amostras de elétrons advindas deste decaimento. A amostra foi selecionada com base em conhecimento especialista, seguindo os princípios dados em [6]. A amostra de ruído é constituída de eventos que não foram aprovados, do ponto de vista da seleção *offline*, por nenhum critério, neste caso jatos hadrônicos. Para aumentar a estatística disponível e objetivando a operação na *Run 3*, optou-se por utilizar todos os dados coletados tanto em 2017 quanto em 2018.

Cada um dos modelos que compõe o *ensemble* é uma rede neural do tipo MLP com uma única camada escondida e um

neurônio do tipo tangente hiperbólica na saída, assim como os neurônios da camada escondida. Para o treinamento, utilizouse o algoritmo *Resilient Backpropagation* (RPROP) [18]. A função custo do treinamento foi o Erro Médio Quadrado (MSE). O critério de parada do treinamento empregado foi baseado no índice SP (Eq. 5), buscando parar o treinamento quando o mesmo estivesse no máximo do índice (SP_{max}).

$$SP = \sqrt{\sqrt{P_D \cdot (1 - P_F)} \cdot \frac{P_D + (1 - P_F)}{2}} \quad (5)$$

onde P_D é a probabilidade de detecção de elétrons e P_F é a probabilidade de classificar como elétron um jato hadrônico.

Aplicou-se a validação cruzada para estimar a incerteza estatística dos modelos obtidos. Para tal, utilizou-se o *jackknife* [7] onde, a partir dos dados, são criadas 10 partições, e 9 destas são utilizadas para o treinamento dos modelos e uma é separada para validação/teste. Em cada uma destas partições, são realizadas 100 inicializações, objetivando evitar a convergência para um mínimo local. Cada inicialização possui um limite máximo de 5000 épocas para o treinamento e o tamanho da batelada é definido pela classe com menor quantidade de eventos.

A escolha da quantidade de neurônios da camada escondida foi feita através de busca, limitando-se a faixa entre 5 até 20 neurônios, devido a resultados anteriores [4]. A escolha final da topologia é realizada avaliando-se o índice SP por meio de *boxplots* (vide Fig. 2) e mantendo-se a parcimônia.




Figura 2. *boxplot* utilizado para avaliação da quantidade de neurônios na camada escondida para uma das regiões do ensemble. No eixo y está o índice SP e no eixo x estão dispostas as topologias testadas.

A avaliação dos modelos foi feita a partir das respostas dadas pelo *NeuralRinger* com 100 anéis (*standard*) e com 88 anéis sem a segmentação hadrônica (*noHAD*), comparando-se com o algoritmo de referência no ATLAS para $E_T < 15$,

que é baseado em cortes bidimensionais de variáveis altamente discriminantes (*CutBased*).

A Colaboração ATLAS possui diversos interesses de estudo dependendo da física de interesse. Devido a isto, o ATLAS assume alguns critérios de aquisição de dados que são:

- Tight: Neste critério, é priorizada a qualidade da amostra.
- Medium: Critério que visa o equilíbrio entre a pureza da amostra e a estatística do processo de interesse.
- Loose: Este é um critério que prioriza o volume estatístico da amostra.
- Very Loose: É um critério alternativo que busca manter elevada a estatística da amostra, porém com maior contaminação.

Para este trabalho, exigiu-se do conjunto de sinal a aprovação no critério Medium, e para o conjunto de ruído de fundo a desaprovação em todos os critérios listados acima. Isto decorre do fato do *offline* validar o *Trigger*.

IV. RESULTADOS

Todos os modelos *standard* e *noHAD* tiveram 5 neurônios na camada escondida. Na Tabela III é possível observar os valores de P_D , P_F e SP para todas as estratégias. Nota-se através da Tabela III que, tanto os modelos *noHAD* e o *standard* possuem melhor desempenho quando comparados ao *CutBased*.

Os modelos *noHAD* mantêm seus índices de detecção P_D muito próximos aos obtidos pelos modelos *standard*. Entretanto, verifica-se um aumento de aproximadamente 4 pontos percentuais (em todos os critérios) no P_F para o modelo *noHAD* que ainda assim mantêm-se abaixo do *CutBased*.

Tabela III
RESULTADOS OBTIDOS PELO *standard* E *noHAD* E A COMPARAÇÃO DA EFICIÊNCIA DO MESMO COM O MÉTODO *CutBased*.

Pontos de Operação	Algoritmos	P_D	P_F	SP
Tight	<i>CutBased</i>	97,86	37,51	79,18
	<i>standard</i>	98,97	14,60	92,06
	<i>noHAD</i>	98,94	17,15	90,72
Medium	<i>CutBased</i>	97,94	40,65	77,43
	<i>standard</i>	99,39	20,69	89,07
	<i>noHAD</i>	99,38	24,41	87,08
Loose	<i>CutBased</i>	97,98	43,36	75,98
	<i>standard</i>	99,59	27,73	85,38
	<i>noHAD</i>	99,59	31,43	83,36
Very Loose	<i>CutBased</i>	98,44	47,46	73,68
	<i>standard</i>	99,62	29,89	84,22
	<i>noHAD</i>	99,60	33,22	82,37

Para analisar de maneira quantitativa o desempenho dos modelos *noHAD* em comparação com os modelos *standard*, dividiu-se o espaço de decisão em quatro regiões mutuamente exclusivas caracterizando quatro casos diferentes, sendo estes definidos abaixo:

- Caso 1: Ambas as estratégias concordam e aprovam o candidato;
- Caso 2: Apenas o *standard* aprova o candidato;
- Caso 3: Apenas o *noHAD* aprova o candidato;

- Caso 4: Ambas as estratégias rejeitam o candidato.

A partir das variáveis utilizadas na identificação de elétrons *offline*, uma vez que identificação *offline* é balizador para *Trigger*, verificou-se a ocorrência destes casos. Espera-se, com base no conhecimento especialista da física, os elétrons aprovados pelo critério Tight devam exibir o valor da variável E_{ratio} o mais próximo possível de 1, semelhantemente a variável R_η também deve estar próximo de 1. Na Fig. 3, apresentamos os resultados para os quatro casos.

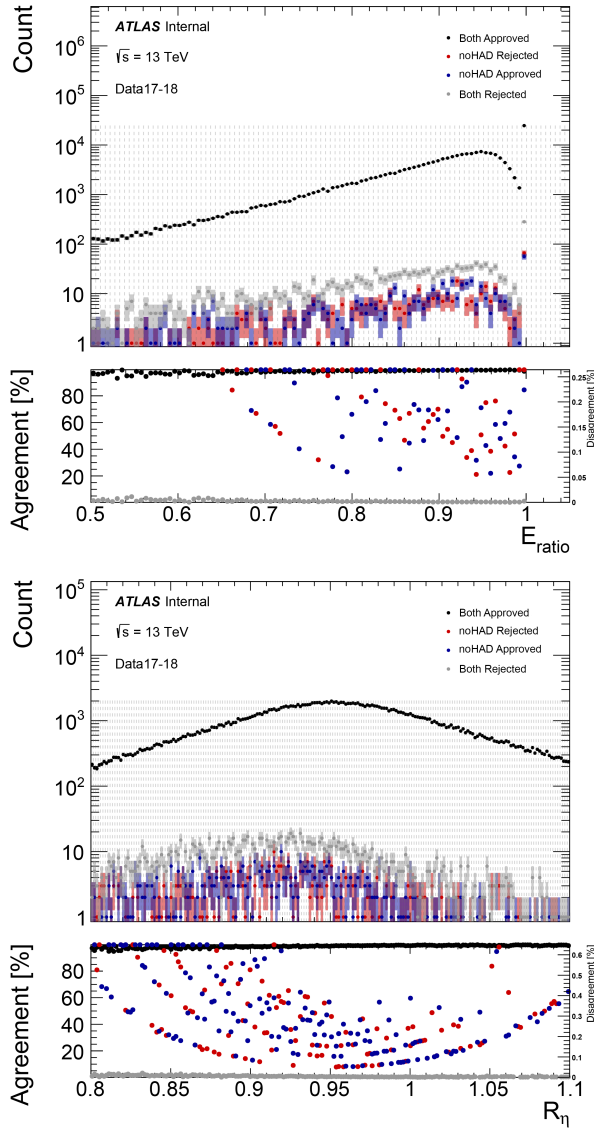


Figura 3. Análise de quadrante (critério Tight) para as variáveis E_{ratio} e R_η nos dados de 2017 e 2018. Em preto encontra-se o Caso 1; em vermelho o Caso 2; em azul o Caso 3 e em cinza o Caso 4.

Comparando as respostas de ambas estratégias do *NeuralRinger*, é observado que, a retirada da seção hadrônica gerou pouco impacto e ambas estratégias concordam na maior parte dos candidatos avaliados, obtendo assim, os valores esperados.

V. CONCLUSÕES

A complexidade dos experimentos de Física de Altas Energias proporciona, para o campo de aprendizado de máquinas, um ambiente propício ao desenvolvimento e avaliação de novas técnicas, devido a enorme quantidade de dados gerados por estes experimentos, a alta dimensionalidade oriunda da fina segmentação dos seus detectores e a enorme quantidade de ruído de fundo que camufla os sinais de interesse.

A proposta de extensão do *NeuralRinger* para região de abaixo de 15 GeV proporciona um melhor desempenho na etapa rápida do *Trigger* de elétrons do ATLAS, uma vez que os resultados mostram que esta mudança de paradigma na tomada de decisão implicará na redução do P_F , mantendo-se o nível de eficiência de detecção em qualquer dos critérios de seleção, dado que, o *NeuralRinger* obteve melhor resultado em todos os critérios de seleção quando comparado com o *CutBased*.

A ausência da informação proveniente dos anéis advindos da seção hadrônica do ATLAS implicou, visivelmente, no aumento do P_F , onde foi possível observar um aumento de 4 pontos percentuais com relação a estratégia *standard*. Entretanto, a detecção foi mantida próxima dos valores obtidos pelo modelo *standard*.

Os resultados obtidos por este trabalho demonstram a capacidade do *NeuralRinger* para atuar na região de $E_T < 15$ GeV e com a possibilidade de operação utilizando apenas a informação da seção eletromagnética do sistema de calorimetria do ATLAS devido sua alta rejeição e alta detecção em comparação com a atual estratégia *CutBased*.

AGRADECIMENTOS

Os autores gostariam de agradecer à FAPERJ, CNPq, RENAFAE e CERN (Suíça) pelo apoio financeiro.

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

REFERÊNCIAS

- [1] Aaboud, Morad, et al. “Electron efficiency measurements with the ATLAS detector using 2012 LHC proton-proton collision data.” *The European Physical Journal C* 77.3 (2017): 195.
- [2] Aad, Georges, et al. “Observation and measurement of Higgs boson decays to $W W^*$ with the ATLAS detector.” *Physical Review D* 92.1 (2015): 012006.
- [3] Aad, Georges, et al. “The ATLAS experiment at the CERN large hadron collider.” *Jinst* 3 (2008): S08003.
- [4] de Araújo, M.V. “Filragem Online Baseada em Calorimetria de Altas Energias e com Alta Taxa de Eventos.” 2019. Dissertação de Mestrado em Engenharia Elétrica, Universidade Federal do Rio de Janeiro.
- [5] ATLAS collaboration atlas. publications@cern.ch, et al. “Measurements of the Higgs boson production and decay rates and constraints on its couplings from a combined ATLAS and CMS analysis of the LHC pp collision data at $\sqrt{s} = 7$ and 8 TeV.” *Journal of High Energy Physics* 2016 (2016): 1-113.
- [6] Cerda Alberich, Leonor. *Photon and electron identification with the ATLAS detector*. No. ATL-PHYS-SLIDE-2016-758. ATL-COM-PHYS-2016-1061, 2016.
- [7] Efron, Bradley, and Gail Gong. “A leisurely look at the bootstrap, the jackknife, and cross-validation.” *The American Statistician* 37.1 (1983): 36-48.
- [8] Evans, Lyndon, and Philip Bryant. “LHC machine.” *Journal of instrumentation* 3.08 (2008): S08001.

- [9] da Fonseca Pinto, Joao Victor. "Ring-shaped Calorimetry Information for a Neural Egamma Identification with ATLAS Detector." *J. Phys.: Conf. Ser.* Vol. 762. No. ATL-DAQ-PROC-2016-007. ATL-COM-DAQ-2016-015, 2016.
- [10] Griffiths, David. Introduction to elementary particles. John Wiley & Sons, 2008.
- [11] Haykin, Simon. *Neural networks: a comprehensive foundation*. Prentice Hall PTR, 1994.
- [12] Levy, Itamar. *Measurement of shower development and its Molière radius with a four-plane LumiCal test set-up*. No. arXiv: 1710.08470. 2017.
- [13] Marshall, Zachary, and Atlas Collaboration. "Simulation of Pile-up in the ATLAS Experiment." *Journal of Physics: Conference Series*. Vol. 513. No. 2. IOP Publishing, 2014.
- [14] The Nobel Prize in Physics 2013. NobelPrize.org. Nobel Media AB 2019. Fri. 24 May 2019. <<https://www.nobelprize.org/prizes/physics/2013/summary/>>
- [15] Palestini, Sandro. "The muon spectrometer of the ATLAS experiment." *Nuclear Physics B-Proceedings Supplements* 125 (2003): 337-345.
- [16] Pequeno, Joao. "Computer generated image of the whole ATLAS detector". No. CERN-GE-0803012. 2008.
- [17] Puzo, P. "ATLAS calorimetry." *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment* 494.1-3 (2002): 340-345.
- [18] Riedmiller, Martin, and Heinrich Braun. "A direct adaptive method for faster backpropagation learning: The RPROP algorithm." *Proceedings of the IEEE international conference on neural networks*. Vol. 1993. 1993.
- [19] Ruiz-Martinez, Aranzazu. *The Run-2 ATLAS Trigger System*. No. ATL-DAQ-SLIDE-2016-026. ATL-COM-DAQ-2015-216, 2016.
- [20] Seixas, J. M., et al. "Neural second-level trigger system based on calorimetry." *Computer Physics Communications* 95.2-3 (1996): 143-157.
- [21] Spolidoro Freund, Werner. *An Ensemble of Neural Networks for Online Electron Filtering at the ATLAS Experiment*. No. ATL-DAQ-PROC-2019-009. ATL-COM-DAQ-2019-067, 2019.
- [22] Wigmans, Richard. *Calorimetry: Energy measurement in particle physics*. Vol. 107. Oxford University Press, 2000.