

Ensemble de Redes Neurais para Identificação Rápida de Elétrons em um Calorímetro com Fina Segmentação e com Alta Taxa de Eventos

Micael Veríssimo de Araújo¹, João Victor da Fonseca Pinto¹, José M. de Seixas¹, Edmar Egidio P. de Souza²,
, Eduardo Furtado S. Filho², Juan Lieber Marin^{2,3}

¹Laboratório de Processamento de Sinais, COPPE/POLI, UFRJ

²Laboratório de Sistemas Digitais, PPGEEC/UFBA

³Instituto Federal da Bahia, Vitória da Conquista, IFBA

Emails: {micael.verissimo, jodafons, seixas}@lps.ufrj.br, {edmar.egidio, eduardo.simas}@ufba.br,
juan.marin@ifba.br

Resumo—Um sistema *online* de seleção de partículas no Experimento ATLAS foi implementado, de modo a lidar com a alta taxa de eventos produzidas durante as colisões de prótons. Neste contexto, elétrons apresentam papel crucial na investigação de partículas e interações raras, entretanto a sua identificação pode ser perturbada devido ao intenso ruído de fundo produzido por partículas de natureza hadrônica. Um sistema baseado em redes neurais artificiais, alimentados por sinais de calorimetria formatados em anéis concêntricos em torno da posição de encontro do elétron com o detector, foi desenvolvido e adotado como padrão pela colaboração ATLAS a partir de 2017 (Run2). Com o atual aumento do número de colisões, taxa de sobreposição dos sinais nos calorímetros, e atualização do hardware de medição de energia, os algoritmos de identificação online de elétrons precisam ser atualizados. Neste trabalho, são apresentados os resultados da atualização da estratégia baseada em aprendizagem de máquina para identificação online de elétrons (NeuralRinger) no ATLAS. Um conjunto de redes neurais artificiais foi projetado para manter as eficiências de identificação de elétrons, e reduzir a taxa de aceitação de falsos positivos, de acordo com as condições de operação atualizadas do experimento.

Index Terms—Identificação online, Redes Neurais, Física de Altas Energias

I. INTRODUÇÃO

O Experimento ATLAS [1] do Grande Colisor de Hádrons (*Large Hadron Collider*) [2] no CERN (Genebra/Suíça) é dotado por uma sofisticada infraestrutura tecnológica, desenvolvida para medir propriedades de partículas subatômicas com elevada precisão. Em particular, o aprendizado de máquina encontra diferentes aplicações em física de altas energias, como na identificação de partículas raras [3], detecção de raios cósmicos [4] e reconstrução em 3 dimensões da propagação de partículas com a matéria [5].

O LHC colide prótons em uma frequência de 40 MHz, com energia de até 14 TeV¹, produzindo na entrada dos sistemas *online* de identificação de partículas uma taxa de até 70 TB/s. No que tange a identificação de elétrons, a

maior parcela deste grande volume de dados produzidos, é em geral composta por elétrons em estados finais produzidos por interações hadrônicas (prótons) que perturbam a identificação de elétrons vindos de bósons Z , importante mediador utilizado para medições precisas de fenômenos raros conhecidos, como o bóson de Higgs [6] [7], e também previstos em modelos de física teórica de interações ainda não medidas experimentalmente.

Para lidar com a alta taxa de eventos, um sistema *on-line* de identificação (*trigger*) foi desenvolvido para detectar partículas de interesse e remover do ruído de fundo. O conceito destes sistemas pode ser encontrado em diversos tipos de experimentos que envolvem instrumentação eletrônica para medição de sinais raros [8] e processamento de grande volume de dados [9], como por exemplo em telescópios [10] e processamento de imagens espaciais [11]. No ATLAS, o sistema de *trigger* é dotado de dois estágios sequenciais, o primeiro implementado em *hardware* no qual efetua uma primeira seleção de eventos, avaliando atributos discriminantes da energia depositada pelas partículas no sistema de calorimetria (arranjo de sensores). Um segundo nível de filtragem, implementado a nível de *software* (HLT - *High Level Trigger*) recebe a informação de decisão do nível anterior e executa uma série de algoritmos de reconstrução dos eventos ocorridos durante as colisões, para uma tomada de decisão mais refinada e então selecionar os eventos que serão gravados em mídia permanente. Na identificação de elétrons, o HLT é subdividido em dois níveis sendo o primeiro acessando apenas a informação de energia disposta nos sensores do calorímetro (reconstrução rápida de calorimetria) e o segundo executando a reconstrução também da trajetória das partículas, utilizando algoritmos mais complexos (reconstrução precisa de calorimetria).

Em 2017, durante o período de execução 2 do LHC (*Run2*) um sistema de classificação baseado em redes neurais artificiais [12] foi adotado como padrão para a identificação *online* de elétrons na etapa de reconstrução rápida de calorimetria. O *NeuralRinger* [13], efetua uma extração de

¹O (eV) é unidade definida como a quantidade de energia cinética obtida por um elétron quando submetido a uma diferença de potencial de 1V no vácuo.

atributos do chuveiro² de partículas com energia decrescente no calorímetro do ATLAS, aproveitando-se das diferenças do espalhamento lateral e longitudinal do depósito de energia por elétrons, quando comparado à jatos hadrônicos. Estas variáveis alimentam um conjunto de redes neurais artificiais treinadas para operar em diferentes regiões do calorímetro, e em diferentes faixas de energia da partícula.

Na *Run3*, período de tomada de dados compreendido entre 2022 - 2026, o ATLAS recebeu diversas atualizações no sistema de *trigger* e aquisição de dados (TDAQ - *Trigger and Data Acquisition*) para lidar com o aumento do número médio de colisões por segundo, aumento da energia das colisões e elevação da média de sobreposição dos sinais medidos nos calorímetros (empilhamento). Este aumento da ocupação do calorímetro distorce o padrão de deposição de energia das partículas, degradando a eficiência dos métodos de estimação de energia. Este problema impacta o desempenho dos algoritmos de filtragem *online*, o que requer investigações para tornar os algoritmos de classificação do sistema de filtragem resilientes ao aumento do empilhamento de sinais. Com tais mudanças nas condições de operação, modificações no HLT foram requeridas. Neste contexto, este trabalho apresenta as atualizações no sistema de classificação inteligente baseado em redes neurais artificiais, para a operação na *Run3*, no qual exigiu novos treinamentos dos modelos neurais, ajustes nos pontos de operação de decisão das redes neurais, testes e validação de desempenho no *software* de controle e operação do experimento.

Este artigo está dividido do seguinte modo: A seção II apresenta os detalhes do sistema de calorimetria e do *trigger* do ATLAS, constando as atualizações do sistema para a *Run3*. A seção III é dedicada para a descrição da metodologia adotada para o treinamento, teste e avaliação do sistema de classificação com redes neurais artificiais, incluindo a descrição dos conjuntos de dados utilizados. A seção IV apresenta os resultados obtidos com a metodologia empregada, o desempenho obtido em dados simulados e dados experimentais. A seção V apresenta as conclusões e trabalhos futuros.

II. O EXPERIMENTO ATLAS

O experimento ATLAS conta com um sofisticado sistema de instrumentação eletrônica e de aquisição de dados, para caracterizar as partículas que resultam das colisões. O ATLAS possui formato aproximadamente cilíndrico, com cerca de 40 m ao longo da extensão axial e 15 m na extensão radial [2]. O ATLAS utiliza um sistema de coordenadas cilíndricas³ para descrever a posição de interação das partículas com o detector. Diversos subsistemas são acomodados ao redor do

ponto de colisão dos feixes de partículas, conforme indicado na Figura 1.




Figura 1: Esquemático do Experimento ATLAS e seus subsistemas.

O ATLAS possui um detector interno (ou detector de traços), sendo composto por sensores para detecção de trajetória de partículas carregadas (importante medida para descrição do momento das partículas). Um complexo sistema de calorimetria foi desenvolvido para medir as propriedades do subproduto gerado nas colisões que deposita energia nestes calorímetros.

O sistema de calorimetria do ATLAS ilustrado na Figura 2 é o responsável por medir a energia das partículas resultantes das colisões.




Figura 2: Sistema de Calorimetria do Experimento ATLAS.

Os calorímetros mais importantes na identificação de elétrons do experimento ATLAS são os calorímetros eletromagnético e hadrônico, sendo ambos em formato cilíndrico e o primeiro posicionado internamente ao segundo, compartilhando o mesmo eixo axial do experimento [1]. O sistema de calorimetria é projetado para fornecer uma cobertura total em ϕ e cobre a faixa de $|\eta| < 4,9$, com fina granularidade na sua área central. O calorímetro EM é um calorímetro de

²Produção em cascata de novas partículas que são produzidas devido a interação entre a partícula vinda de uma colisão com o material dos sensores.

³O ATLAS usa um sistema de coordenadas baseado na mão direita, com sua origem no ponto de interação (*PI*) no centro do detector e o eixo z ao longo do feixe de prótons. O eixo x é direcionado a partir do *PI* até o centro do anel do LHC e o eixo y é perpendicular a este plano. As coordenadas cilíndricas (r , ϕ) são usadas no plano transversal, com ϕ sendo o ângulo azimutal em torno do eixo z . A pseudo rapidez é definida em termos do ângulo polar θ como $\eta \equiv -\ln [\tan(\theta/2)]$.

amostragem de chumbo/argônio líquido (*Liquid-Argon - LAr*) com geometria em formato de acordeão [1].

O barril (região central do detector) é dividido em duas metades e dois componentes da extremidade. A região de transição entre o barril e as tampas das extremidades contém material inativo (*crack*), região na qual são acomodados cabos de alimentação de energia e comunicação. O calorímetro EM é segmentado em três camadas longitudinais (EM1, EM2 e EM3) na direção da perpendicular a propagação do chuveiro de partículas desenvolvido no calorímetro. Três camadas de calorímetro hadrônico circundam o calorímetro EM (HAD0, HAD1 e HAD2) utilizadas para medir energia de partículas com natureza hadrônica. Na região frontal, uma camada chamada pré-amostrador (PS) fina, cobrindo o intervalo de $|\eta| < 1,8$, é usada para estimar a perda de energia das partículas antes de chegarem ao calorímetro.

A. Sistema de Trigger do ATLAS

Com uma frequência de colisões a 40 MHz, onde 1 evento gerado por colisões de partículas pode obter $\approx 1,7$ MB, uma taxa de até ≈ 70 TB/s de informação pode ser gerada na entrada dos sistemas de filtragem do ATLAS. O sistema de filtragem de elétrons desenvolvido para a *Run3* é ilustrado na Figura 3 onde o L1Calo indica a etapa baseada em *hardware* seguido do HLT e suas subetapas implementadas em *software*.

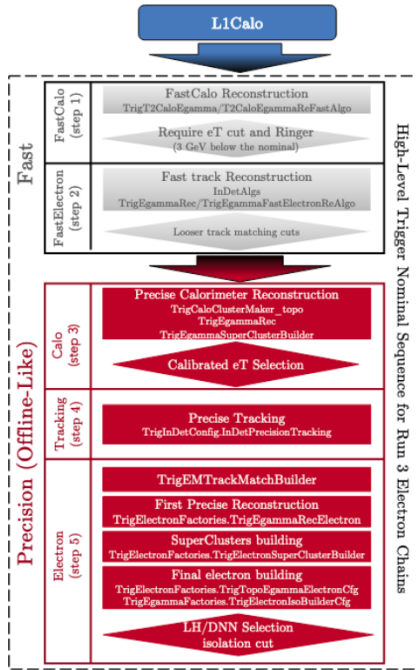


Figura 3: Diagrama do sistema sequencial (*trigger*) de seleção online de elétrons no experimento ATLAS.

B. Identificação Online de Elétrons

Elétrons são partículas essenciais para os estudos de medidas precisas de forças e interações conhecidas, assim como estão ligados com decaimentos físicos raros, e também com modelos teóricos que indicam a existência de novas




Figura 4: Estrutura em anéis gerada pelo algoritmo *Neural-Ringer* para descrição do espalhamento lateral e longitudinal do chuveiro de partículas.

partículas/interações fundamentais mas que ainda não foram verificadas experimentalmente. A identificação de elétrons é uma tarefa importante para o programa de física do experimento, entretanto sua detecção enfrenta desafios devido ao intenso ruído de fundo produzido por partículas de outras naturezas. Neste contexto, um sistema dedicado de filtragem de elétrons foi desenvolvido para lidar com a enorme taxa de produção de informação, remover a maior parcela de ruído de fundo e manter elevada a eficiência de identificação.

Inicialmente, no *L1Calo*, sistema de seleção implementado em *hardware*, realiza a leitura de um conjunto de células do calorímetro na qual uma partícula incidiu (Região de Interesse) e computa variáveis discriminantes relacionadas com o espalhamento lateral do chuveiro e razão de energia depositada nos calorímetros eletromagnético hadrônico. Uma vez aprovado no *L1Calo* o evento é submetido à uma etapa subsequente implementada a nível de *software* (*FastCalo*) realiza cortes mais sofisticados. Nesta etapa, o algoritmo *NeuralRinger* [14] realiza uma extração de características topológicas da energia que se espalha lateralmente e longitudinalmente nas células dos calorímetros. Anéis são gerados em torno da célula mais excitada, e é realizada a soma das energias de cada célula que pertencem há um determinado anel.

A Tabela I mostra a quantidade de anéis gerados em cada camada do calorímetro para cada evento aceito pelo *L1Calo*. Após a reconstrução da informação anelada, os anéis alimentam um *ensemble* de redes neurais artificiais com uma única camada oculta, que foram treinadas para operar em diferentes faixas de energia e posição de interação da partícula com o detector conforme exposto na Tabela II. Caso o evento seja aprovado, uma série de algoritmos de reconstrução (usando mais informações dos calorímetros e também do detector interno) são executados para refinar a decisão final para armazenagem do evento. A etapa precisa do *trigger* executa algoritmos com configurações muito próximas aos algoritmos de processamento *offline* de candidatos a elétrons.

Considerando as atualizações no sistema de *trigger*, aumento do nível de empilhamento de sinais ($\langle \mu \rangle$) e diferentes

Tabela I: Número de anéis gerados em cada camada dos calorímetros.

PS	EM1	EM2	EM3	HAD1	HAD2	HAD3	Total
4	32	4	4	2	2	2	50

Tabela II: Regiões de η e E_T utilizada na *ensemble* do *NeuralRinger*. São utilizadas, no total, 40 regiões.

Composição do <i>ensemble</i>								
Fronteira das Regiões em E_T [GeV]								
4	7	10	15	20	30	40	50	$E_T > 50$
Fronteiras das Regiões em $ \eta $								
$0,0 \leq \eta < 0,8$				Barril				
$0,8 \leq \eta < 1,37$				Barril Estendido				
$1,37 \leq \eta < 1,54$				Crack				
$1,54 \leq \eta < 2,37$				Tampa				
$2,37 \leq \eta < 2,47$				Final da Tampa				

condições de operação para o período da *Run3*, foram requeridas também atualizações no algoritmo *NeuralRinger*, de modo a ajustar os pontos de operação requeridos para diferentes conjuntos de elétrons a serem armazenados em mídia permanente. Novos treinamentos, testes e avaliações de modelos neurais foram realizados de modo a atender as restrições e taxas requeridas para a nova operação do *trigger* de elétrons para a *Run3*.

III. METODOLOGIA

A. Descrição do Conjunto de Dados

Neste trabalho diferentes conjuntos de dados foram utilizados no percurso de atualização do sistema inteligente de classificação, para o período de tomada de dados *Run 3*. Conjuntos de dados simulados por processos de Monte Carlo foram utilizados, por faixa de energia da partícula. Para a faixa de $E_T \geq 15$ GeV a classe de sinal foi composta por elétrons em estados finais vindos do decaimento do bóson Z ($Z \rightarrow e^+e^-$), enquanto para energias abaixo de 15 GeV a amostra de sinal é formada por elétrons em estado final advindos do decaimento do méson J/Ψ ($J/\Psi \rightarrow e^+e^-$)⁴, e a classe de ruído de fundo em ambos os casos foi composta por elétrons produzidos por jatos hadrônicos (*JF17* - jatos de prótons com distribuição de energia transversa em torno de 17 GeV).

Em 2022, um conjunto de dados simulados (MC21) foi utilizado para treinamento e testes dos modelos neurais, constando basicamente a modelagem geométrica do detector e eletrônica de aquisição em condições muito próximas do final do período de tomada de dados *Run 2* em 2018. Um segundo conjunto de dados simulados (MC23) foi adotado para a atualização dos modelos neurais e ajustes dos pontos de operação, no qual contém as atualizações das condições geométricas do detector, novos algoritmos de reconstrução, nova eletrônica de processamento do L1Calo e nível de empilhamento de sinais

⁴Utilizou-se amostras de elétrons advindas do decaimento *prompt* do méson J/Ψ , onde o não há um hádron B intermediário antes dos estados finais.

	[0,0, 0,8)	[0,8, 1,37)	[1,37, 1,54)	[1,54, 2,37)	[2,37, 2,47)
[3, 7) GeV	elétrons: 398704 jatos: 1427178 s/b (%): 27,94	elétrons: 94034 jatos: 880823 s/b (%): 10,68	elétrons: 4367 jatos: 104396 s/b (%): 4,18	elétrons: 136181 jatos: 1040802 s/b (%): 13,08	elétrons: 11645 jatos: 74541 s/b (%): 15,62
[7, 10) GeV	elétrons: 265558 jatos: 1989517 s/b (%): 13,35	elétrons: 116269 jatos: 1608080 s/b (%): 7,23	elétrons: 7387 jatos: 229510 s/b (%): 3,22	elétrons: 106888 jatos: 1901081 s/b (%): 5,62	elétrons: 11185 jatos: 157893 s/b (%): 7,08
[10, 15) GeV	elétrons: 150001 jatos: 2002312 s/b (%): 7,49	elétrons: 65657 jatos: 1612771 s/b (%): 4,07	elétrons: 6152 jatos: 347475 s/b (%): 1,77	elétrons: 66286 jatos: 2021326 s/b (%): 3,28	elétrons: 6794 jatos: 141100 s/b (%): 4,82

Figura 5: Total de amostras de disponível para o treinamento dos modelos para as regiões com $E_T < 15$ GeV.

	[0,0, 0,8)	[0,8, 1,37)	[1,37, 1,54)	[1,54, 2,37)	[2,37, 2,47)
[15, 20) GeV	elétrons: 54616 jatos: 885633 s/b (%): 6,17	elétrons: 33678 jatos: 696932 s/b (%): 4,83	elétrons: 10795 jatos: 182741 s/b (%): 5,91	elétrons: 47728 jatos: 914267 s/b (%): 5,22	elétrons: 4427 jatos: 72512 s/b (%): 6,11
[20, 30) GeV	elétrons: 378633 jatos: 573538 s/b (%): 66,02	elétrons: 217606 jatos: 446258 s/b (%): 48,76	elétrons: 65897 jatos: 120756 s/b (%): 54,57	elétrons: 246454 jatos: 568907 s/b (%): 43,32	elétrons: 22124 jatos: 53376 s/b (%): 41,45
[30, 40) GeV	elétrons: 1053785 jatos: 162047 s/b (%): 650,30	elétrons: 626867 jatos: 124849 s/b (%): 502,10	elétrons: 160679 jatos: 34853 s/b (%): 461,02	elétrons: 575275 jatos: 155212 s/b (%): 370,64	elétrons: 47875 jatos: 14502 s/b (%): 330,13
[40, 50) GeV	elétrons: 1196995 jatos: 60656 s/b (%): 1973,42	elétrons: 755580 jatos: 47151 s/b (%): 1602,47	elétrons: 144717 jatos: 13387 s/b (%): 1081,03	elétrons: 674536 jatos: 56647 s/b (%): 1190,77	elétrons: 53228 jatos: 4923 s/b (%): 1081,21
$E_T \geq 50$	elétrons: 440027 jatos: 59272 s/b (%): 742,39	elétrons: 279262 jatos: 47774 s/b (%): 584,55	elétrons: 56602 jatos: 13226 s/b (%): 427,96	elétrons: 236493 jatos: 54241 s/b (%): 436,00	elétrons: 17146 jatos: 4518 s/b (%): 379,50

Figura 6: Total de amostras de disponível para o treinamento dos modelos para as regiões com $E_T \geq 15$ GeV.

atualizados conforme operação da *Run 3*. Nas Figuras 5 e 6 estão dispostas a quantidade amostras disponíveis para o treinamento do *NeuralRinger* com o conjunto de dados MC23.

Os novos modelos foram implementados no sistema de *trigger* e avaliados nas primeiras *runs* de 2025, de modo a verificar o seu desempenho e dados. A *Run 498434*, foi utilizada neste trabalho para mostrar os resultados operacionais durante as colisões de prótons. Nesta rodada de colisões, o pico de nível de empilhamento foi de ≈ 64 , usando 2400 pacotes de prótons (*bunch crossings*), em uma energia de colisão de 13,6 TeV.

B. Treinamento e Avaliação do Ensemble de Redes Neurais Artificiais

O treinamento das Redes Neurais que compõem o *NeuralRinger* é realizado de maneira individual, possibilitando o tratamento individual para cada região a depender da ener-

gia e posição da partícula. Contudo, experimentos anteriores levaram a convergência de uma arquitetura capaz de atingir as exigências do *trigger* de elétrons sem a necessidade do aumento significativo da mesma, assim cada uma das Rede Neural foram treinadas seguindo os parâmetros dispostos na Tabela III.

Tabela III: Arquitetura e parâmetros de treinamento dos modelos *NeuralRinger*.

Descrição	Parâmetros
Arquitetura do modelo	MLP
Número de camadas escondidas	1
Neurônios na camada escondida	5
Função de ativação (camada escondida)	ReLU
Neurônios na camada de saída	1
Função de ativação (saída)	Sigmóide
Algoritmo de otimização	ADAM [15]
Função custo	<i>Binary Crossentropy</i>
Tamanho da batelada	1024
Número máximo de épocas	5000
Critério de parada	Máximo do índice SP (Eq. 1)
Parada Antecipada	25 épocas
Validação cruzada	<i>Stratified k-fold</i>
Número de subconjuntos	10 (9 para treino e 1 teste)

A figura de mérito adotada para interromper o treinamento foi o índice SP ((1)), este índice busca equilibrar o P_D ((2)) e o F_A ((3)) proporcionando a balanceamento entre estas duas grandezas.

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

onde P_D (Equação (2)) é a probabilidade de detecção de elétrons e falso alarme (F_A) (Equação (3)) é a probabilidade de classificar como elétron um jato hadrônico.

$$P_D = \frac{V_p}{V_p + F_n}, \quad (2)$$

onde V_p são os eventos verdadeiros positivos (quantidade de elétrons corretamente classificados), e F_n são os elétrons incorretamente classificados como jatos hadrônicos (falsos negativos).

$$F_A = \frac{F_p}{F_p + V_n}, \quad (3)$$

em que F_p é a quantidade de elétrons da classe de jatos hadrônicos incorretamente classificados como elétrons oriundos do bóson Z , e V_n é a quantidade de elétrons da classe de jatos hadrônicos corretamente classificados.

A método escolhido para avaliar a incerteza associada aos conjuntos de dados e aos modelos treinamentos foi o método de *K-Fold* estratificado com 10 *folds*. Além disso, foram realizadas 5 inicializações em cada um dos *fold* e manteve-se apenas a melhor destas inicializações baseado na avaliação do índice SP (de modo a avaliar a dispersão dos resultados dos modelos neurais, devido a natureza estocástica do procedimento de otimização utilizado para treinamento das redes neurais).

Finalizado o processo de treinamento, para obter os pontos de operação necessários para operação do *trigger*, os modelos são submetidos à um ajuste linear para mitigar os efeitos

oriundos do empilhamento. Para realização deste ajuste a não-linearidade presente na última camada de cada um dos modelos é removida e substituída por uma saída linear e então os patamares de decisão de aceite são obtidos em função do empilhamento conforme a (4), com isso a eficiência de cada ponto de operação é mantida praticamente inalterada mesmo em altos níveis de empilhamento.

$$\kappa(\langle\mu\rangle) = \alpha\langle\mu\rangle + \beta \quad (4)$$

onde κ é o limiar de decisão ad rede neural, $\langle\mu\rangle$ é o índice de empilhamento e α e β são coeficientes obtidos.

C. Estratégia de Comissionamento no Sistema de Trigger do ATLAS

Após o treinamento, teste e avaliação das redes neurais artificiais, os modelos neurais foram implantados no *software* de controle do experimento. Para verificar o desempenho dos novos modelos, uma série de *Reprocessings*⁵ foi realizada, para avaliar os modelos em condições muito próximas a de operação em coleta de dados reais. Para isso, dois novos subconjuntos de dados de Monte Carlo, que reproduziram a campanha de 2021 e 2024, foram gerados, compostos por uma amostra de 100,000 elétrons em cada campanha. Estes conjuntos com apenas a amostra de sinal foram utilizados para verificar as eficiências dos modelos neurais, e ajustes dos pontos de operação. Após esta verificação os modelos foram postos em operação para funcionamento no ATLAS durante as colisões de prótons do LHC.

IV. RESULTADOS

Os resultados dos treinamentos estão exibidos na Tabela IV. Os novos treinamentos baseados em MC23 obtiveram redução de até 3,2 pontos percentuais em relação ao falso alarme (F_A) para o ponto de operação *Tight*, e até 3,77 pontos percentuais de redução de F_A para o ponto de operação *Very Loose*, considerando as mesmas taxas de detecção (P_D). Esta melhoria de resultado pode ser atribuída aos seguintes fatos: novo algoritmo de seleção do L1Calo, que diferentemente do implementado no conjunto MC21, realiza cortes rígidos mais bem ajustados em *shower shapes* em *hardware*, o que promove uma maior pureza da amostra utilizada para o treinamento dos modelos neurais⁶.

Tabela IV: Tabela com os valores da validação cruzada considerando o ajuste de empilhamento.

Operação	Tight		Very Loose	
	P_D	F_A	P_D	F_A
MC21	99,42	17,23	99,69	18,70
MC23	99,40±0,01	13,81±0,26	99,68±0,01	14,93±0,33

Para lidar com a influência da perturbação do nível de empilhamento na reconstrução da energia medida nas células do

⁵Execução centralizada dos algoritmos de reconstrução e de identificação de eventos, que simula as condições de operação do experimento.

⁶Para o MC21 o L1 aplicou apenas cortes rígidos em níveis de energia, com seleção mais simples dos quais são aplicados no MC23.

calorímetro, o ajuste dos limiares de decisão das redes neurais foram obtidos em função do índice de empilhamento. Uma função linear incluída na saída da rede após o treinamento, foi ajustada (substituindo a função sigmoide utilizada durante o ajuste dos modelos), para manter a mesma probabilidade de detecção, a medida que o empilhamento varia durante as colisões. Operacionalmente, durante as colisões, o detector de luminosidade (LUCID) provê a informação instantânea de empilhamento aos modelos neurais, que ajustam a decisão da rede de modo online para manter a mesma probabilidade de detecção durante as colisões. A Figura 7 apresenta a saída da rede neural para amostras de sinal e jatos, treinada para a faixa de energia 30 - 40 GeV, na região do calorímetro compreendida entre $0, 0 < |\eta| < 0,8$. Observa-se que o limiar da rede varia entre 0 a aproximadamente -2 em função do aumento do empilhamento, para manter uma taxa de P_D em 99,64% nesta região do calorímetro.

Na Figura 8 é apresentada a comparação entre as eficiências obtidas utilizando conjunto de dados simulados por Monte Carlo em diferentes campanhas para o comissionamento do *NeuralRinger*. Neste trabalho são mostradas as eficiências para uma cadeia de filtragem *HLT_e26_lhtight_ivarloose_L1eEM26M*⁷. O atual treinamento (linha vermelha) apresentou melhor desempenho se comparado aos modelos neurais treinados que operaram no *trigger* do ATLAS entre 2022 e 2024 (MC21). A melhoria no desempenho pode ser observada principalmente nas faixas de energia em ≈ 100 GeV e 150 GeV.

Este aumento de eficiência pode ser também observado em função da posição de interação da partícula no detector, na coordenada η , conforme indicado na Figura 9. É observado melhoria de desempenho principalmente nas regiões do *end-cap* (região mais distante do centro do detector, com valores mais altos em $|\eta|$). Este resultado é esperado, uma vez que foram incluídos patamares de decisão mais brandos, para uma maior aceitação de sinal nessas regiões. Este ajuste, foi realizado de modo a reduzir a perda de eficiência de identificação de elétrons nestas regiões durante a tomada de dados experimentais entre 2022 e 2024.

Uma análise foi realizada para verificar o desempenho dos modelos treinados durante a operação do *trigger*, no início do período de tomada de dados de 2025. Os novos modelos neurais foram instalados na etapa rápida de reconstrução do *trigger*. Os resultados em dados experimentais podem ser observados na Figura 10, no qual apresenta a comparação entre as eficiências obtidas em MC23 e dados da *Run 498434*. É possível verificar uma queda de eficiência em até 3% da operação em dados reais se comparado a dados simulados,

⁷Uma cadeia de *trigger* é composta por diferentes requerimentos que configuram os algoritmos sequências. Para a cadeia *HLT_e26_lhtight_ivarloose_L1eEM26M* são aprovados elétrons com energia ≥ 26 GeV, que tenham sido aprovados nos critérios mais rígidos (*lhtight*), que sejam aprovados por cortes rígidos em variáveis de isolamento de calorimetria (medida de concentração de energia em um determinado raio a partir da célula com maior energia, e que tenha sido aprovado pelo requerimento médio (M) de L1 a partir de 26 GeV.




Figura 7: Saída da rede neural em função do índice de empilhamento de sinais utilizando o conjunto MC23 para amostras de elétron (7b) e para amostras de jatos(7a). As marcações em azul indicam o valor necessário do patamar de decisão para que seja atingida a eficiência necessária para aquele nível de empilhamento, enquanto a linha sólida em preto indica o ajuste linear obtido.

principalmente nas faixas de energia que compreendem o intervalo de 60 GeV - 170 GeV.

De modo a entender em qual região do calorímetro a queda de eficiência está relacionada, uma análise foi realizada em função da posição da partícula no detector, conforme indicado




Figura 8: Comparação da eficiência de identificação de elétrons das versões do NeuralRinger treinadas com amostras de Monte Carlo 2023 e 2021, em função da energia transversa da partícula.




Figura 10: Comparação da eficiência de identificação de elétrons em dados simulados e experimentais, em função de E_T .




Figura 9: Comparação da eficiência de identificação de elétrons das versões do NeuralRinger treinadas com amostras de Monte Carlo 2023 e 2021, em função da posição de interação da partícula no calorímetro.




Figura 11: Comparação da eficiência de identificação de elétrons em dados simulados e experimentais, em função de η .

na Figura 11. Verifica-se que as maiores diferenças estão relacionadas com a região $|\eta| > 1.47$, o que é esperado, uma vez que a descrição de calorimetria em MC apresenta consideráveis diferenças em relação a dados para esta região (células maiores, imperfeita modelagem de material morto - como cabos e conexões que passam através de algumas partes do detector nesta região).

Na Figura 12 é apresentada a eficiência de identificação de elétrons entre as tomadas de dados de 2024 e 2025 (*Runs* 486658 e 498434 respectivamente) para a cadeia de identificação com corte mínimo de aceitação em 26 GeV. É possível verificar que os novos treinamentos obtêm melhor eficiência para toda a faixa de energia compreendida

entre ≈ 30 e 250 GeV. A melhora do desempenho está diretamente associada com a recuperação da eficiência na região do calorímetro mais distante o ponto central, conforme indicado na Figura 13, na qual é possível verificar que os novos treinamentos e ajustes do limiar de decisão permitem a recuperação da eficiência principalmente na faixa de $|\eta| > 1.8$. Tais resultados são esperados uma vez que os novos treinamentos foram realizados baseados nas condições de operação mais atualizadas do detector, e um ajuste do limiar de decisão das redes neurais para as regiões do calorímetro mais distantes do ponto central foram flexibilizados, para recuperar a eficiência nestas regiões.

V. CONCLUSÃO

Os experimentos de físicas de altas energias proporcionam um ambiente rico para aplicações de aprendizado de máquinas,




Figura 12: Comparação da eficiência de identificação de elétrons em Runs de 2024 x 2025, em função de E_T .




Figura 13: Comparação da eficiência de identificação de elétrons em Runs de 2024 x 2025, em função de η .

graças a enorme quantidade de dados que são gerados nos experimentos além da busca por eventos raros. A atualização do *NeuralRinger* foi essencial para manter a estabilidade e a alta eficiência do sistema de filtragem de elétrons do ATLAS.

Os resultados apresentados indicam melhora de desempenho dos modelos que compõem o conjunto de redes neurais. Melhorias de desempenho foram obtidas principalmente em regiões do calorímetro afastadas do ponto central, com um detalhado ajuste do limiar de decisão para recuperar as eficiências nessas regiões. Como próximas etapas deste trabalho destaca-se a avaliação do impacto desta atualização nas *shower shapes* que descrevem os elétrons. Esta é uma etapa importante posto que, distorções nestas variáveis podem acarretar na deterioramento da identificação precisa (e *offline*) dos elétrons podendo mascarar algum processo raro. Modelos de redes neurais profundas devem ser avaliados, bem como a sua viabilidade dentro das restrições de tempo de execução no

trigger de elétrons do ATLAS.

AGRADECIMENTOS

Os autores gostariam de agradecer a FAPERJ, FAPESB, CNPq, RENAFAP 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] ATLAS Collaboration, “The ATLAS experiment at the CERN Large Hadron Collider,” *Journal of Instrumentation*, vol. 3, no. 08, pp. S08 003–S08 003, aug 2008. [Online]. Available: <https://doi.org/10.1088/1748-0221/3/08/s08003>
- [2] L. Evans and P. Bryant, “LHC machine,” *Journal of Instrumentation*, vol. 3, no. 08, pp. S08 001–S08 001, aug 2008.
- [3] S. Y. Kuzu, A. Karasu Uysal, and M. Kaya, “Enhancing precision in j/ψ mass estimation: A study of ensemble and deep learning methods,” *Computer Physics Communications*, vol. 310, p. 109534, 2025.
- [4] A. Demichev and A. Kryukov, “Using deep learning methods for iact data analysis in gamma-ray astronomy: A review,” *Astronomy and Computing*, vol. 46, p. 100793, 2024.
- [5] X. Yang, Z. Quan, Y. Dong, and M. et al., “Application of a deep learning method for shower axis reconstruction in a 3d imaging calorimeter,” *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, vol. 1066, p. 169571, 2024.
- [6] ATLAS Collaboration, “Evidence for Higgs boson decays to a low-mass dilepton system and a photon in pp collisions at $\sqrt{s} = 13$ TeV with the ATLAS detector,” *Physics Letters B*, vol. 819, p. 136412, 2021.
- [7] ATLAS-Collaboration, “Observation of a new particle in the search for the standard model higgs boson with the ATLAS detector at the LHC,” *Physics Letters B*, vol. 716, no. 1, pp. 1–29, 2012.
- [8] H. M. Gray, “Future colliders for the high-energy frontier,” *Reviews in Physics*, vol. 6, p. 22, 2021.
- [9] R. Garcia, M. Anzorena, J. Valdés-Galicia, Y. Matsubara, T. Sako, E. Ortiz, A. Hurtado, R. Taylor, O. Musalem, L. González, Y. Itow, T. Kawabata, K. Munakata, C. Kato, W. Kihara, Y. Ko, S. Shibata, H. Takamaru, A. Oshima, T. Koi, H. Kojima, H. Tsuchiya, K. Watanabe, M. Kozai, and Y. Nakamura, “Particle identification and analysis in the sciirt using machine learning tools,” *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, vol. 1003, p. 165326, 2021.
- [10] S. Spencer, T. Armstrong, J. Watson, S. Mangano, Y. Renier, and G. Cotter, “Deep learning with photosensor timing information as a background rejection method for the cherenkov telescope array,” *Astroparticle Physics*, vol. 129, p. 102579, 2021.
- [11] I. Shilon, M. Kraus, M. Büchele, K. Egberts, T. Fischer, T. Holch, T. Lohse, U. Schwanke, C. Steppa, and S. Funk, “Application of deep learning methods to analysis of imaging atmospheric cherenkov telescopes data,” *Astroparticle Physics*, vol. 105, pp. 44–53, 2019.
- [12] S. S. Haykin, *Neural networks and learning machines*, 3rd ed. Upper Saddle River, NJ: Pearson Education, 2009.
- [13] G. Aad et al., “Performance of electron and photon triggers in ATLAS during LHC Run 2,” *Eur. Phys. J. C*, vol. 80, no. 1, p. 47, 2020.
- [14] ATLAS Collaboration, “Performance of electron and photon triggers in ATLAS during lhc run2,” *Eur. Phys. J. C*, vol. 80, no. 47, pp. P2–P41, sep 2019.
- [15] D. P. Kingma, “Adam: A method for stochastic optimization,” *arXiv preprint arXiv:1412.6980*, 2014.