

Sistema de filtragem *Online* Utilizando um *Ensemble* de Redes Neurais e Informação de Calorimetria para Operar em Altas Taxas de Eventos

João V. F. Pinto, Werner S. Freund e José M. Seixas

Universidade Federal do Rio de Janeiro (UFRJ)
Rio de Janeiro, RJ, Brasil

E-mails: jodafons@cern.ch, wsfreund@cern.ch, seixas@lps.ufrj.br

Resumo Diversas aplicações na engenharia estão relacionadas em ambientes cujo a alta taxa de eventos e a rara ocorrência são uma dificuldade a ser superada. Este artigo tem como proposta apresentar a nova estratégia de seleção de elétrons no sistema de filtragem *Online* do detector ATLAS, no CERN, utilizando técnicas multivariadas, como Redes Neurais, para selecionar eficientemente e reduzir o custo de processamento na fazenda de computadores durante a filtragem. Dentro desse contexto, serão apresentadas as estratégias de treinamento das redes e correção das eficiências mediante ao crescimento do empilhamento de eventos ocasionado pelo aumento da luminosidade das colisões para o cenário de 2017.

Keywords: Rede Neural, Classificador, Redes Neurais, *Ensemble*, Calorimetria, Filtragem *Online*, *Trigger*

1 Introdução

O crescente número de soluções que utilizam técnicas multivariadas em diversas aplicações tem surgido como resposta ao aumento da quantidade de dados disponíveis e ao crescimento do grau de complexidade em que um problema pode ser descrito. Em problemas de classificação, como o abordado neste trabalho, diversas técnicas de pré-processamento, treinamento e interpretação dos dados podem ser tomadas como caminho para a otimização de sistemas de filtragem complexos.

Sistemas de filtragem de dados são ferramentas empregadas em diversas áreas, com o objetivo de separar um conjunto de sinais de interesse daqueles que não agregam informação relevante ao problema. Atualmente, devido à complexidade de certos problemas, tem-se que o volume de informação a ser analisada torna-se bastante grande, de forma que a dimensão do espaço original de dados de entrada tende a ser consideravelmente elevada, dificultando o processo de análise dos mesmos.

Adicionalmente, em ambientes de alta taxa de eventos, é esperado que a velocidade com a qual a filtragem é realizada atenda aos limites físicos estabelecidos

pela implementação da ferramenta e a taxa com o qual espera-se que os eventos sejam gerados. O que é extremamente importante quando planeja-se que o sistema opere de maneira *Online*. Por último, tratando-se de eventos raros onde é necessário uma grande quantidade de dados para observar um único evento de interesse, o sistema deve ser extremamente eficiente em detectar o evento com o qual deseja-se analisar e rejeitar eventos sem interesse para o propósito da aplicação.

A utilização de sistemas de filtragem hierárquicos tem sido bastante explorado em diversas aplicações relacionadas à Física de partículas. Dentro deste contexto, parte dos experimentos buscam detectar partículas específicas, ou até mesmo provar modelos físicos baseados em partículas jamais observadas. Como é o caso do experimento *Large Hadron Collider* (LHC) e o detector ATLAS, que foi concebido com o objetivo de identificar principalmente a partícula de Higgs, descoberta entre as colisões de 2011 e 2012.

Em números, o subproduto da colisão de pacotes de prótons no detetor gera uma taxa de 40MHz de informação. Se todos esses eventos produzidos fossem armazenados, este detetor produziria 60TB de informação por segundo, tornando impossível seu armazenamento físico para as condições do projeto. Nesse contexto, um sistema de filtragem *Online* de eventos eficiente é indispensável e a otimização de um de seus níveis é a proposta deste trabalho.

2 O Experimento *A Toroidal LHC ApparatuS* (ATLAS)

O CERN (*the European Organization for Nuclear Research*) é o maior centro de pesquisas em física de partículas do mundo, situado na fronteira da Suíça com a França. O experimento de maior repercussão do CERN atualmente é o LHC (*Large Hadron Collider*), um acelerador de partículas de 27 km de circunferência que irá atingir energia de colisões nunca antes obtidas experimentalmente.

Neste experimento, de proporções de colaboração internacional, serão acelerados pacotes¹ de prótons em feixes com sentidos opostos onde ocorrerão colisões em quatro pontos. Nesses pontos, foram instalados detectores de partículas. O ATLAS (*A Toroidal LHC ApparatuS*) é o maior detetor do mundo, construído por uma colaboração internacional de 174 institutos e 38 países. Este detetor foi projetado de modo a atender os diversos requisitos solicitados pelos estudiosos da área de forma a realizar o estudo geral da matéria. Com todos esses requisitos, o detetor possui aproximadamente 140 milhões de canais de leitura e está dividido nos seguintes subdetectores:

- Detector Interno (ID), ou *Inner Detector*, é responsável pela detecção da trajetória de partículas carregadas;
- Calorímetro Eletromagnético (ECAL), cujo objetivo é realizar a absorção total da energia de partículas eletromagnéticas;
- Calorímetro Hadrônico (HCAL), que de maneira similar ao eletromagnético, realiza a absorção da energia de partículas hadrônicas;

¹ Um aglomerado de partículas.

- Espectrômetro de Múons, camada mais externa do detector, realiza a identificação e determinação da trajetória de Múons.




Figura 1: O detector ATLAS em diferentes níveis de detalhe. A ilustração do canto superior esquerdo representa a visão subterrânea da caverna onde está instalado o detector. O esquemático no canto inferior esquerdo representa em detalhes a estrutura em volta do detector. Modificado de [2]

A Figura 1 representa a localização de cada um dos sistemas do Detector ATLAS. Devido a física de interesse ser extremamente rara, são necessários diversos dias de colisão para se observar o evento de interesse.

3 Contexto

Em problemas de filtragem *Online*, onde os diferentes níveis de *Trigger* são implementados de forma hierárquica, é atraente, sempre que possível, otimizar os primeiros níveis da cadeia. Em outras palavras, é desejável que eventos que seriam posteriormente eliminados em sistemas de filtragem mais complexos, como os níveis hierárquicos superiores, sejam eliminados pelos níveis inferiores. Assim, esses sistemas mais complexos se encarregariam de eventos que realmente necessitem de algoritmos mais complexos para sua discriminação.

O foco deste trabalho será na otimização do sistema de filtragem *Online* de alto nível do ATLAS na etapa de Calorimetria do *Trigger* rápido. Aqui, será implementado um novo algoritmo de extração de característica combinado com um algoritmo de hipótese baseado em redes neurais artificiais do tipo *Multi Layer Perceptron* [3], na etapa de pre-seleção eficiente do calorímetro. A estrutura da nova cadeia de execução do *Trigger*, do canal de elétrons está representada na Figura 2

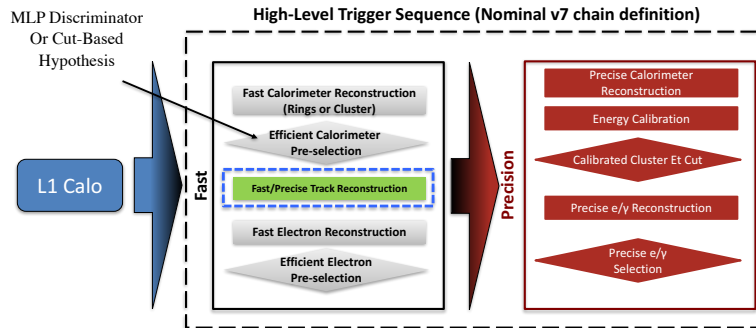


Figura 2: Cadeia de execução do *Trigger* de elétrons implementada no detector ATLAS para o novo cenário da *Run 2*. Modificado de [4]

4 Identificação de Elétrons

A principal tarefa para a identificação de elétrons, canal de estudo deste trabalho, pode ser resumida em um problema de classificação de duas classes: elétrons (sinal) e hádrons (ruído). Com o aumento da luminosidade, a quantidade de ruído processado pelo ATLAS aumenta exponencialmente. Nesse cenário, o aumento de eventos, em especial hádrons, eleva o processamento de eventos na fazenda de *Trigger*. Como a estrutura do *Trigger* é implementada de forma hierárquica, do algoritmo mais simples ao mais robusto, uma otimização nas primeiras etapas diminui consideravelmente o custo de processamento e alocação de máquina nas etapas seguintes.

4.1 *Menu de Trigger*

Como o *Trigger* é um sistema hierárquico, o *menu de Trigger* é definido como um conjunto de algoritmos organizados em cadeia (*chain*) e especializados na identificação de um canal de interesse para uma determinada configuração. Essa configuração pode conter diferentes estratégias e técnicas que podem ser ou não combinadas dependendo do *menu*.

Durante a *Run 1*, a extração de características utilizando as variáveis físicas de caracterização do chuveiro de partículas foram largamente utilizadas em conjunto com duas estratégias de classificação nos calorímetros. Na subseção 4.2, é descrita a estratégia inicial implementada utilizando cortes lineares. Com o aumento da luminosidade, adotou-se uma estratégia multivariada para a identificação de elétrons descrita na subseção 4.3. O método proposto em 4.4, por sua vez, explora a extração de características utilizando a soma de energia em anéis como entradas para alimentar um conjunto de redes neurais especialistas (hipótese).

O *menu de Trigger* pode combinar diferentes algoritmos de extração e técnicas de discriminação em uma única cadeia. Para 2017, adotou-se a implementação

do método proposto no segundo nível de filtragem (*FastCalo*) como forma de propor a substituição do algoritmo de extração de chuveiro e cortes lineares neste nível e diminuir a carga computacional de processamento de eventos não interessantes para a física (ruído) nas etapas subsequentes. Além dessa redução no custo, o método proposto foi alocado de forma a reduzir a taxa de ruído antes da execução dos algoritmos de traço que, por sua vez, possuem os maiores custos em termos de processamento na fazenda do ATLAS.

4.2 Contes Lineares (*Cut-based*)

Essa estratégia considera a informação discriminante dos chuveiros para a separação de elétrons e hádrons. Nesse sistema, utilizam-se cerca de 9 grandezas com grande potencial de síntese de processo no calorímetro que podem ou não ser combinadas com outra fonte de discriminação proveniente do ID. Sendo este último de grande custo computacional para a cadeia de processamento na fazenda. Em geral, utilizam-se cortes nas variáveis provenientes do calorímetro (rapidamente obtidas pelo sistema de reconstrução) como forma de reduzir a taxa de ruído e em seguida aplica-se um sistema mais acurado utilizando informações de outros detectores como o traço (ID).

4.3 Likelihood (*lh*)

O ATLAS empregou uma estratégia multivariável baseada em *Naïve Bayes* para aumentar a eficiência devido as condições mais rígidas de operação. Isso permitiu o emprego de grandezas discriminantes com maior sobreposição entre sinal e ruído, bem como o emprego de grandezas menos discriminantes em cortes menos rígidos. Diversos outros métodos multivariáveis foram avaliados pelo ATLAS, como redes neurais, *Boosted Decision Trees*, entre outros, porém a escolha por *Naïve Bayes* deu-se por sua simplicidade de construção e rapidez de execução.

Além da nova estratégia de hipótese, foi levando em consideração um ajuste das saídas com relação ao aumento de empilhamento. Vale ressaltar, que esse algoritmo de hipótese utiliza como entradas as variáveis físicas que descrevem os chuveiros de partículas e podem ou não fazer uso, dependendo do nível da cadeia, das informações provenientes do ID.

4.4 Algoritmo Proposto: *Ringer*

O Algoritmo proposto [5, 6, 4] explora a geometria cônica do formato do chuveiro utilizando as células do calorímetro para descrever a quantidade de energia depositada em cada anel concêntrico em torno da célula mais energética do evento. Cada camada do calorímetro possui um número específico de anéis. A Figura 3 representa a passagem de uma partícula carregada pelo detector de traço até encontrar as camadas do calorímetro e ser absorvida.

Ao ser absorvida pelo calorímetro, o algoritmo busca a célula mais energética na segunda camada Eletromagnética. Essa célula será o primeiro, representado




Figura 3: Visualização do sistema de montagem de anéis do algoritmo de extração de características do *ringer*.

em vermelho na Figura. As células adjacentes ao primeiro anel serão somadas para formar o segundo anel. Esse processo é repetido até um número determinado de anéis. As outras camadas do calorímetro utilizam a posição da célula mais quente na segunda camada como referência para o seu primeiro anel.

O Tabela representada na Figura 3 mostra a quantidade de anéis em cada uma das 7 camadas do calorímetro eletromagnético e hadrônico, totalizando 100 anéis, que serão utilizados para alimentar um discriminador neural previamente treinado na etapa de hipótese. A concepção do algoritmo de seleção de eventos leva em conta dois conhecimentos prévios sobre o problema.

O primeiro deles está relacionado ao comportamento das partículas em relação faixa de energia (E_T). Na calorimetria, os jatos, em sua grande maioria, ocorrem em faixas de energia menores que 15 GeV. Em geral, elétrons que possuam essa energia tendem a ser confundidos com jatos devido ao comportamento parecido. Em contra-partida, partículas de mais alta energia são mais fáceis de serem caracterizadas devido a melhor resposta das células do calorímetro para essa faixa.

Por fim, o segundo conhecimento prévio está relacionado a própria estrutura do detector em η . O calorímetro está dividido em 4 regiões, sendo elas: O Barril, que cobre grande parte da região do calorímetro entre $0 \leq |\eta| < 0,8$; A Tampa, entre $0,8 \leq |\eta| < 1,37$; O *Crack*, região morta do detector, entre $1,37 \leq |\eta| < 1,54$ com baixa resolução devido a passagem de cabos e o Barril estendido com $1,54 \leq |\eta| \leq 2,5$.

5 Método

A estratégia de treinamento do algoritmo de hipótese do *ringer*, utiliza redes especialistas do tipo *Multi Layer Perceptron* para cada um dos setores da grade ($E_T, |\eta|$) onde $E_T = [15, 20, 30, 40, 50, \infty] GeV$ e $|\eta| = [0, 0.8, 1.37, 1.54, 2.5]$, totalizando 20 setores especializados em energia e posição. A escolha da grade preserva as características da geometria do detector e o comportamento das par-

ticulas em cada faixa de energia mas também leva em consideração a estatística dos eventos em cada setor. Uma grade mais granulada poderia ocasionar em baixa estatística em alguns setores e prejudicar o treinamento dos classificadores.

No algoritmo, as informações de posição e energia do evento irão selecionar a rede especialista previamente treinada para aquela região e gerar o discriminante. Sendo um problema de classificação, a saída da rede será comparada com um limiar de corte. Caso o discriminante seja maior ou igual ao corte, ele será aceito pelo algoritmo de hipótese e propagado para o sistema de filtragem superior, caso contrário, será rejeitado pelo sistema de filtragem.

A arquitetura utilizada foi aquela com melhor desempenho variando-se a quantidade de neurônios na camada escondida da rede neural de 5 até 20. A rede possui somente uma camada escondida de neurônios e somente um neurônio na camada de saída. Todos os neurônios têm a função tangente hiperbólica como função de ativação, onde elétrons são mapeados pelo neurônio de saída em '1' e jatos em '-1'. Diversas normalizações já foram estudadas [7]. Concluiu-se que a normalização mais satisfatória é a divisão do valor de cada anel pela soma do valor de todos os anéis extraídos.

O algoritmo de treinamento utilizado foi o *resilient backpropagation* [8], devido à sua rápida convergência. Os pesos sinápticos da rede são ajustados por batelada, considerando o MSE (Mean Square Error), como função a ser minimizada. Como a quantidade de elétrons e de jatos, para alguns casos, é muito diferente, a quantidade de eventos utilizadas na batelada é definida pela classe com o menor número de exemplares no treinamento. Posteriormente, para cada época, escolhe-se aleatoriamente a mesma quantidade de eventos da classe mais numerosa.

Um método de validação cruzada foi implementado para estimar o impacto da flutuação estatística dos dados utilizados no desempenho dos discriminadores. O método utilizado consiste em dividir o conjunto total de dados em N subgrupos (caixas), de forma aleatória. Define-se, então, uma quantidade K de sorteios, onde cada sorteio consiste em escolher aleatoriamente N subgrupos para formar o conjunto de treino, e restante para formar o conjunto de teste. O modelo de escolha das caixas foi baseado no método do *Jack-Knife*.

Originalmente, esse método utiliza N sorteios, onde cada sorteio $N-1$ amostras são utilizadas para o treinamento. No sorteio seguinte, a amostra retirada é colocada de volta no conjunto e então uma outra amostra é retirada. Ao final dos N sorteios, todas as amostras devem ter sido retiradas ao menos uma vez.

Assim, no sorteio das caixas, escolhe-se $N-1$ subgrupos para o treinamento e 1 subgrupo para teste. O conjunto de teste também é utilizado como conjunto de validação do treinamento, a fim de evitar o super-treinamento das redes neurais. Normalmente, em experimentos de física de partículas, a quantidade produzida de eventos, seja por simulações, seja por aquisições em experimentos reais, é suficiente para a caracterização estatística do processo físico de interesse. Dessa forma, não é necessário dividir a base de dados em três conjuntos distintos, como usualmente é feito em projetos de redes neurais.

Neste trabalho, N e K são definidos como 10. O número de inicializações da rede para escapar do mínimo local em cada sorteio foi definido como 100 rodadas.

5.1 Critérios de Seleção das Redes

O algoritmo de seleção da melhor rede durante o treinamento foi modificado para produzir até três configurações de pesos diferentes ao final do treinamento. Esses discriminadores são obtidos pelo critério *save the best* durante o treinamento para os casos:

- Ajustada pela detecção: Durante cada época, o limiar de corte da rede é ajustado até a o discriminador produzir uma determinada probabilidade de detecção. Para essa mesma detecção, a configuração de pesos que produzir o menor falso alarme será salva.
- Ajustada pelo Falso Alarme: Ao contrário do primeiro caso, o limiar da rede é ajustado até produzir um determinado falso alarme. A configuração de pesos que produzir a maior probabilidade de detecção será salva.
- Máximo SP: Diferente dos casos anteriores onde a rede é ajustada para uma determinada configuração, a configuração de pesos que produzir o maior SP será salva. O índice SP (Soma-Produto) é um fator de mérito que balanceia a probabilidade de detecção e o falso alarme e é dada pela equação:

$$SP = \sqrt{\sqrt{P_d \times (1 - F_a)} \times \frac{(P_d + (1 - F_a))}{2}} \quad (1)$$

Onde P_d é a probabilidade de detecção de elétrons, e F_a a taxa de falso alarme do discriminador. Assim, quanto maior o índice SP, mais balanceado estará o classificador.

Como no sistema de *Trigger* o critério utilizado é a taxa de detecção será utilizado 4 pontos de operação diferentes ajustados para terem a mesma detecção do algoritmo do antigo algoritmo padrão utilizado. Os pontos de operação são nomeados como: *VeryLoose* (*vloose*), possui uma alta taxa de detecção e alto falso alarme. Em geral, é utilizada para coleta de dados para o treinamento dos classificadores a posteriori; *Loose*, é o mesmo conceito, porém possui menor falso alarme e detecção; O *Medium* é ajustado para operar no meio entre o *Loose* e o *Tight*; O *Tight*, por sua vez, é um critério de maior pureza. Possui baixo falso alarme e consequentemente uma detecção menor que nos casos anteriores.

5.2 Correção do Corte com Relação ao Aumento de Luminosidade.

Com o aumento de luminosidade nas colisões do LHC, houve uma degradação na eficiência dos algoritmos de *Trigger* utilizados pela colaboração durante a *Run 1*. Para a *Run 2*, uma estratégia de ajuste foi utilizada para compensar essa perda de eficiência de detecção no ambiente de alta luminosidade. Para realizar esse ajuste, foi implementada uma grade $(E_T, |\eta|)$ de limiares de corte

variáveis. Diferentemente da grade utilizada no ajuste dos pesos e na seleção da rede, a grade de limiares pode assumir uma maior granularidade uma vez que a estatística não é um limitante.

Como o ajuste da eficiência da rede é linear removeu-se a tangente hiperbólica da saída da rede para retirar a não linearidade da saída do discriminador e tornar o ajuste mais suave. Durante as colisões a informação de empilhamento do evento é fornecida para os algoritmos de hipótese. Assim, os cortes das redes neurais foram ajustados para obterem a eficiência exigida para cada um dos setores em cada valor de $\langle \mu \rangle$ (média de empilhamento).

Embora as redes tenham sido treinadas utilizando dados de simulação de Monte Carlo de 2015, os limiares da rede foram ajustados utilizando todos os dados reais coletados em 2016. Uma comparação entre as distribuições da saída da rede entre simulação e colisão observou um deslocamento da distribuição de sinal para a esquerda em dados de colisão. Assim, foi considerado ajustar a saída da rede em colisão para adaptar os classificadores na operação em dados de colisão para o cenário de 2017.

6 Resultados

Para operar efetivamente em 2017, o novo algoritmo de hipótese proposto não pode impactar nas eficiências finais do *Trigger* no canal de elétrons. A construção das eficiências levou em consideração a probabilidade de detecção das cadeias de elétrons definidas pela colaboração para cada um dos critérios de seleção exigidos pelo *menu* de *Trigger*: *tight*, *medium*, *loose* e *veryloose*.

As melhores redes treinadas com dados de simulação de Monte Carlo foram ajustadas para operar com as eficiências obtidas em dados de colisão nos dados de 2016. Além do ajuste de eficiência, foi aplicada uma correção nos cortes dos discriminadores com relação ao empilhamento utilizando uma reta do tipo $thr = a(\langle \mu \rangle) + b$ como demonstrado na Figura 4. A Figura 4 representa a curva de eficiência de um dos setores antes e depois da correção das eficiências aplicando o ajuste pela nova reta de corte em relação a variação do empilhamento das partículas no detector.

Observa-se que após a correção do corte da rede neural para esse setor, a curva de eficiência não apresentou um comportamento de queda como visto na solução onde o corte da rede era fixo. Esse procedimento foi realizado para todos os setores na grade de limiar de corte definidos para o algoritmo proposto.

Além da probabilidade de detecção exigida pelo sistema de filtragem é conveniente que o algoritmo de possua baixo falso alarme ou alta taxa de rejeição de ruído. Diferentemente do antigo algoritmo (variáveis de entrada baseadas no chuveiro e cortes lineares) utilizado pela colaboração, a seleção pelo sistema proposto (anéis mais rede neural) no nível de *Trigger* de estudo consegue obter um fator de redução de aproximadamente 3 vezes no falso alarme dependendo do critério configurado pelo *menu*. A Tabela 1 representa os valores de falso alarme para cada uma das etapas do sistema de trigger do ATLAS após o primeiro nível de filtragem realizado em *hardware* utilizando o critério *tight*.

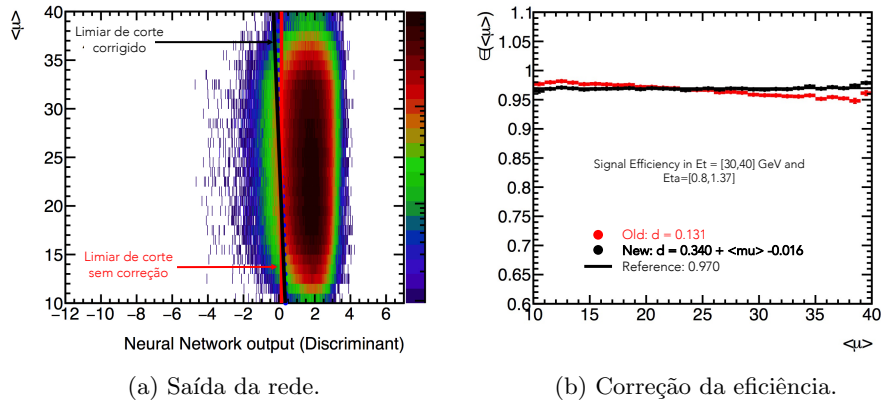


Figura 4: Representação da estratégia de correção de eficiência (a) considerando a variação de empilhamento do evento e a saída da rede neural após o somador do neurônio de saída. Os pontos em azul representam o limiar de corte que a rede deve ter para obter a eficiência exigida no setor para um determinado valor de empilhamento. A reta em vermelho representa o limiar de corte fixo obtido durante o treinamento. A reta em preto representa o novo corte após o ajuste linear dos pontos em azul. As eficiência (b) antes e depois da correção estão representadas pelos pontos vermelhos e pretos respectivamente.

Após avaliar a probabilidade de detecção considerando o sinal e a alta taxa de rejeição de ruído, o sistema proposto foi posto em operação em meados de maio de 2017 para realizar o comissionamento do novo *Trigger* de elétrons do ATLAS. Os resultados a seguir representam as eficiências do método proposto com relação ao sistema de filtragem utilizado no *Trigger* de elétrons, para o critério *tight*, no período em que este trabalho foi avaliado.

Dentro desta análise, o método proposto (*trigger*) obteve exatamente a mesma eficiência de detecção de elétrons quando comparado com a cadeia utilizada como *baseline*. Analisando as curvas de energia (Figura 5a) e η (Figura 5b) não é observado qualquer ineficiência introduzida pelo sistema proposto. Quanto aos valores de rejeição de ruído, para todas as configurações avaliadas, o falso alarme manteve-se dentro do esperado, preservando, assim, a característica de alta rejeição presente na técnica multivariada utilizada neste trabalho.

7 Conclusão

A operação do *ensemble* de redes neurais manteve a taxa de detecção equivalente aquela do paradigma anterior bem como resiliência equivalente ao efeito de empilhamento. Além da operação semelhante, em termos de detecção, essa técnica aliviou o gargalo de processamento causado pelas cadeias de elétrons na fazenda do HLT devido a sua alta rejeição de eventos caracterizados como *background* (*Hádrons*) pela rede neural. Com relação aos eventos aceitos pelo novo

	<i>Fast Calo</i> [%]	<i>Fast Electron</i> [%]	<i>Precise Calo</i> [%]	HLT [%]
<i>ringer</i>	4.92	4.52	4.44	0.53
<i>baseline</i>	14.38	13.93	13.71	0.54

Tabela 1: Para as configurações avaliadas, a versão *baseline* utiliza a extração de características do chuvaeiro no *FastCalo* combinado com um corte linear, cortes lineares nas variáveis provenientes do ID na etapa *Fast Electron*, corte em energia no *Precise Calo* e um *Naïve Baises* combinado com variáveis do ID e chuvaeiros no último estágio. No entanto, a versão *ringer* utiliza a extração de características baseado em anéis combinada com redes neurais especialistas no nível do *FastCalo*. As demais etapas são semelhantes a configuração mencionada anteriormente. Ambas configurações foram ajustadas para trabalhar com a taxa de aceitação utilizando o critério *tight* como exemplo.

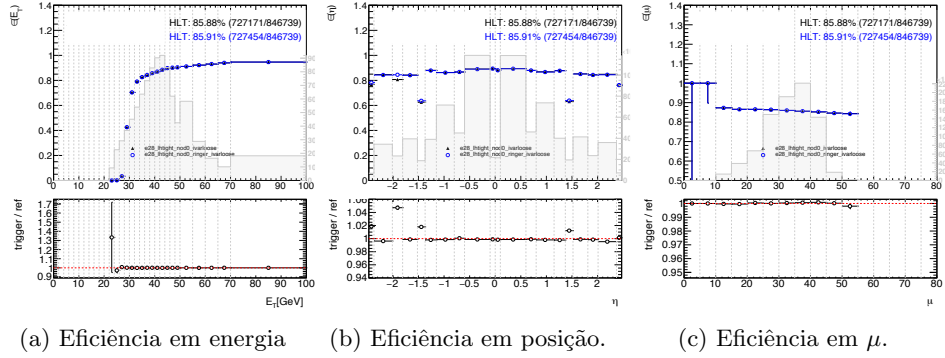


Figura 5: Performance dos algoritmos *ringer* (azul) e *baseline* (preto) para uma configuração de uma cadeia *tight* na última etapa de *Trigger* do ATLAS. O histograma em cinza representa a estatística presente nas amostras em dados de colisão avaliadas. A Figura (a) representa as curvas de eficiência de ambas as cadeias; A Figura (b) avalia a eficiência considerando a posição do detector. Por fim, a Figura (c) representa a comparação entre as cadeias com relação a variação de empilhamento dos eventos.

sistema, foram realizadas análises de forma a buscar possíveis sistemáticas introduzidas pela técnica de redes neurais no *Trigger*. Os estudos não apontaram desvios e introdução de sistemática na análise das variáveis descritivas dos elétrons.

Dentro desse contexto, a colaboração optou por introduzir o algoritmo proposto neste trabalho como forma de aliviar a carga computacional exigida no novo cenário enfrentado. Além dessa proposta, existe uma outra onde o sistema de anelamento é proposto para o sistema de filtragem *Offline* do ATLAS. Esse sistema ainda esta sendo estudado e mostra-se bastante promissor com relação a separação de elétrons e hádrons.

Agradecimentos

Desenvolveu-se essa pesquisa com o apoio de CNPq, CAPES, RENAFAE (MCTI), FAPERJ e do Núcleo Avançado de Computação de Alto Desempenho (NACAD) da COPPE, Universidade Federal do Rio de Janeiro (UFRJ); bem como da União Européia, que apoiou o trabalho através do projeto E-PLANET. Os autores agradecem também à colaboração do Experimento ATLAS pelas frutíferas discussões a respeito deste trabalho.

Referências

1. Lyndon Evans e Philip Bryant. “LHC Machine”. Em: *Journal of Instrumentation* 3.08 (2008), S08001. URL: <http://stacks.iop.org/1748-0221/3/i=08/a=S08001>.
2. *ATLAS Experiment*. Acessado em 10 de agosto de 2017. URL: http://atlasexperiment.org/what_is_atlas.html.
3. Simon Haykin. *Neural Networks and Learning Machines*. 3ª ed. Prentice Hall, 2008.
4. Joao Victor Da Fonseca Pinto. *Ring-shaped Calorimetry Information for a Neural EGamma Identification with ATLAS Detector*. Rel. téc. ATL-DAQ-PROC-2016-007. Geneva: CERN, mar. de 2016. URL: <https://cds.cern.ch/record/2142761>.
5. J.M. Seixas et al. “Neural second-level trigger system based on calorimetry”. Em: *Computer Physics Communications* 95.2 (1996), pp. 143–157. ISSN: 0010-4655. DOI: [https://doi.org/10.1016/0010-4655\(96\)00012-4](https://doi.org/10.1016/0010-4655(96)00012-4). URL: <http://www.sciencedirect.com/science/article/pii/0010465596000124>.
6. R. Desalvo et al. “A novel way of electron identification in calorimeters”. Em: *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment* 279.3 (1989), pp. 467–472. ISSN: 0168-9002. DOI: [https://doi.org/10.1016/0168-9002\(89\)91293-X](https://doi.org/10.1016/0168-9002(89)91293-X). URL: <http://www.sciencedirect.com/science/article/pii/016890028991293X>.
7. Rodrigo Torres. “Sistema *online* de filtragem em um ambiente com alta taxa de eventos e fina granularidade”. Tese de Doutorado em Engenharia Elétrica. Rio de Janeiro: COPPE, Universidade Federal do Rio de Janeiro, 2010.
8. Martin Riedmiller e Heinrich Braun. “A Direct Adaptive Method for Faster Backpropagation Learning: The RPROP Algorithm”. Em: *Proceedings of the IEEE International Conference on Neural Networks*. San Francisco, USA, 1993, pp. 586–591.