

Redes Neurais para Classificação de Partículas usando Informação de Calorimetria de Altas Energias para Seleção Online de Múons

Pedro H. Grave Lima
LPS¹
UFRJ²

Rio de Janeiro, RJ, Brasil
pedrolima@lps.ufrj.br

Natanael N. Moura Junior
LPS¹
UFRJ² - COPPE

Rio de Janeiro, RJ, Brasil
natmourajr@lps.ufrj.br

Luciano M. de Andrade Filho
NIPS³
UFJF⁴

Juiz de Fora, MG, Brasil
luciano.andrade@ufjf.br

Resumo—O experimento ATLAS no LHC do CERN enfrenta o desafio de processar um volume de dados extremamente elevado, demandando sistemas de filtragem eficientes em tempo real, onde a detecção de múons é particularmente suscetível a altas taxas de falso alarme. Este estudo propõe a substituição do filtro casado, atualmente empregado para identificação de múons no calorímetro TileCal, por classificadores baseados em redes neurais que utilizam um conjunto mais abrangente de células do detector. Foram avaliadas arquiteturas de redes neurais *MultiLayer Perceptron* (MLP) e *Convolutional Neural Network* (CNN), comparando-as com o método de corte rígido de energia. Os resultados indicam que o uso de redes neurais permite reduzir a taxa de falso alarme de aproximadamente 35% para 9-17% em regiões críticas do detector, mantendo uma probabilidade de detecção fixa de 98%. Tais avanços podem otimizar a seletividade do *trigger* e a eficiência do sistema de detecção de múons no ATLAS em um ambiente de alta luminosidade.

Palavras-Chave—redes neurais, aprendizado de máquina, filtragem online, processamento de sinais

I. INTRODUÇÃO

O ATLAS [1] é um experimento de detecção de partículas de propósito geral, localizado no LHC do CERN. Para tanto, conta com quatro subdetectores: Pre-Sampler, Calorímetro de Argônio Líquido (LAr), Calorímetro de Telhas (TileCal) e Espectrômetro de Múons. Cada um desses subsistemas possui funções específicas; o TileCal é responsável por medir a energia de partículas hadrônicas e absorvê-las, enquanto a identificação de múons, tradicionalmente, é realizada pelo espectrômetro de múons. Neste trabalho, investiga-se o uso do TileCal [2] como sistema auxiliar na detecção de múons. Este calorímetro é composto por chapas de aço e cintiladores, onde partículas emitem luz por meio da radiação de Cherenkov, que é coletada por fibras ópticas e convertida em sinais elétricos. O detector é dividido em dois segmentos e dois lados, totalizando quatro partições (*Long Barrel A e C, Extended Barrel A e C*).

Agradecimentos a: CAPES, CNPq, FAPERJ, RENAFAE, CERN e Colaboração ATLAS pelo apoio.

¹Laboratório de Processamento de Sinais (LPS)

²Universidade Federal do Rio de Janeiro (UFRJ)

³Núcleo de Instrumentação e Processamento de Sinais (NIPS)

⁴Universidade Federal de Juiz de Fora (UFJF)

Cada partição é dividida em *Trigger Towers*, uma seleção dos canais associados a faixas de valores da coordenada azimutal (η), cada uma contendo uma seleção dos canais das células contidas em um intervalo de $0,1 \eta$. Os sinais são amostrados a cada 25 ns em janelas de 7 amostras, formando pulsos cuja amplitude é proporcional à energia da partícula.




Figura 1: Esquemático da divisão do TileCal em intervalos de η e suas respectivas células, extraído de: [3]

Embora projetado para detecção de hádrons, a partícula múon também deposita uma pequena quantidade de energia no TileCal, o que possibilita sua identificação no calorímetro hadrônico, especialmente em regiões com baixo ruído. Sistemas anteriores, como a *Tile Muon Digitizer Board* (TMDB) [4], já exploraram essa capacidade ao digitalizar o pulso e estimar sua energia, usando filtro casado, a partir de canais das células D5 e D6 (as mais externas na figura 1) e alertando o espectrômetro de múons sobre possíveis eventos, otimizando recursos computacionais.

Uma das abordagens mais simples para identificação de múons é o método *Cut-Based*, no qual se aplica um corte rígido sobre a energia estimada por algoritmos como o *Optimal Filter* (OF) [5], já presente no TileCal. Ao analisar a distribuição da energia depositada por múons, define-se o ponto de operação como um limiar que garante pelo menos 98% de Probabilidade de Detecção (P_D).




Figura 2: Histograma com a estimação de energia do algoritmo de OF para eventos aleatórios (vermelho) e eventos de múon (azul) para a *Trigger Tower* A1. Valores acima do limiar (preto) são aceitos como sinal, o Falso Alarme (F_A), ou FR, representa a porcentagem do conjunto de ruído erroneamente classificado como sinal.

Como mostra a figura 2, o F_A é proveniente da interseção entre a distribuição de sinal e *background*. A torre selecionada (A1) é uma das torres centrais, assim possuindo uma das melhores relações sinal-ruído, com a taxa de falso alarme em 4%. No entanto, essa relação se deteriora para as torres mais externas e próximas da região de transição entre LB e EB do TileCal. Para mitigar esse problema, propomos o uso de **redes neurais artificiais** como alternativa ao Cut-Based. Foram avaliadas três arquiteturas:

- **E-MLP (Energy-based MLP)**: uma rede MLP que usa como entrada apenas a energia estimada pelo OF;
- **S-MLP (Sample-based MLP)**: uma MLP que usa como entrada as 7 amostras dos canais da torre, achatadas em um vetor unidimensional;
- **CNN**: uma rede convolucional que utiliza como entrada uma matriz $7 \times N$, sendo 7 as amostras temporais e N o número de canais da torre.

Os dados usados para treinamento são experimentais de colisões próton-próton em 2023, onde o sinal foi obtido por meio de uma coincidência com a reconstrução do sistema de múons, assim obtendo um conjunto de eventos mais restritivo. O treinamento das redes foi conduzido utilizando o método de validação cruzada k -fold, com $k = 5$. Isso significa que o conjunto de dados foi dividido em 5 partes, e em cada iteração, 4 partes foram usadas para treinamento e 1 parte para validação, sendo cada parte usada uma vez como conjunto de validação. A avaliação de desempenho foi feita com base em curvas ROC, com o ponto de operação fixado em $P_D = 98\%$, replicando a exigência dos sistemas atuais. A F_A nesse ponto foi usada como principal métrica de comparação entre os métodos. A seleção da melhor rede foi feita com base no índice SP, que avalia a separação das classes na saída da rede, o que deve ser o maior possível.

Nas próximas seções, será detalhado o método de operação

atual do TileCal e as mudanças advindas da migração para o *High-Luminosity LHC* (HL-LHC), incluindo o aumento de luminosidade e o impacto na detecção de múons. Posteriormente, será descrito o conjunto de dados utilizado para o treinamento dos modelos, bem como a arquitetura das redes neurais propostas. Finalmente, serão apresentados os resultados comparativos obtidos, demonstrando como a solução proposta viabiliza a detecção de múons no detector em conformidade com os requisitos de tempo real e os recursos de hardware da atualização para a nova fase.

II. OPERAÇÃO ATUAL E ATUALIZAÇÃO

Atualmente, a detecção e estimação de energia de múons no TileCal é feita pela TMDB [4], cada uma das 16 placas é responsável pela digitalização e processamento em tempo real dos 2 canais (DXR e DXL) de 2 células D (especificamente D5 e D6) de 8 módulos em cada lado do barril estendido do TileCal, assim totalizando 32 canais por placa, 512 ao todo.

Cada TMDB utiliza uma FPGA para amostrar o pulso elétrico gerado pelos fotomultiplicadores a cada 25 ns, formando janelas de sete amostras por evento. Sobre esses pulsos aplica-se um filtro casado, cujo coeficiente é calibrado com dados experimentais e a estimativa do OF [5]. A saída do filtro fornece um valor aproximado da energia do evento. Quando a energia estimada excede um corte arbitrário de 500 MeV, a TMDB sinaliza ao sistema de *trigger* de múons do ATLAS a possível presença de um múon no canal correspondente. No total, o sistema é responsável pela identificação de múons dentro da faixa de $1,0 < \eta < 1,3$.

Entretanto, com a evolução para o HL-LHC, toda a eletrônica de leitura do ATLAS será simplificada e realocada para fora do volume do calorímetro. Nessa nova arquitetura, os sinais de todas as células serão digitalizados e transmitidos continuamente, sem a necessidade de módulos dedicados como a TMDB. Como consequência, a TMDB será descontinuada, pois sua função de pré-filtragem local deixa de ser compatível com o fluxo de dados *streaming* e com o conceito de *trigger* unificado do sistema atualizado. Além disso, o algoritmo deve ser resiliente ao empilhamento de sinal (*pile-up*) [6], que ocorrerá com a maior ocupação do detector devido à alta luminosidade.

Visando preencher essa lacuna, o presente estudo propõe dar continuidade ao princípio de detecção auxiliar de múons da TMDB, porém estendendo-o e aprimorando-o para a nova infraestrutura. Em vez de limitar-se às células D5 e D6, esta abordagem explora todas as células em cada torre, ampliando a cobertura em η além do intervalo atual. Além disso, o filtro casado é substituído por modelos de redes neurais — implementáveis em FPGAs — capazes de lidar de forma mais robusta com sinais com ruído não-gaussiano e alto empilhamento de sinal [6]. Esta estratégia mantém a lógica física original (baseada na persistência do sinal de múon nas células externas) e, ao mesmo tempo, aproveita a nova capacidade de transmissão contínua de dados, garantindo que regiões adicionais do espectrômetro de múons possam ope-

rar com menor carga de processamento sem comprometer a sensibilidade global do sistema.

III. MÉTODOS DE CLASSIFICAÇÃO DE MÚONS NO TILECAL

Nesta seção, são delineadas as abordagens investigadas para a identificação de múons no calorímetro TileCal, valendo-se de todas as amostras temporais e canais da torre de disparo. Foram considerados o método tradicional de filtro casado (TMDDB) e duas arquiteturas de redes neurais: Perceptron Multicamadas (MLP) e Rede Neural Convolucional (CNN).

A. Considerações Iniciais

Para estruturar o problema de detecção [7], é definida uma janela de análise composta pelas 7 amostras consecutivas de cada um dos N canais da torre. Denotemos por $r_j[k]$ a k° -ésima amostra do canal j ; então montamos o vetor

$$\mathbf{x} = [r_1[1], \dots, r_1[7], r_2[1], \dots, r_N[7]]^T \in \mathbb{R}^{7N}.$$

A tarefa é aprender uma função de decisão

$$f: \mathbb{R}^{7N} \rightarrow \{0, 1\},$$

onde 1 indica presença de múon e 0 ausência. Em vez de pressupor modelos estatísticos fixos para sinal e ruído, utilizamos classificadores treinados com exemplos rotulados, extraindo padrões temporais e inter-canal que diferenciam pulsos de múon de flutuações de fundo.

B. Método Cut-Based

Como base de comparação para os modelos de redes neurais, foi implementado um classificador simples baseado em corte rígido de energia. Essa abordagem, apesar de sua simplicidade, serve como uma linha de base interpretável e reproduzível para avaliar o ganho obtido com métodos mais sofisticados.

Para cada evento, soma-se a energia estimada pelo *Optimal Filter* em todos os canais da torre de disparo. Essa soma é tratada como uma variável escalar de entrada. Ao se construir o histograma dessa variável, conforme a figura 2, observa-se tipicamente uma distribuição bimodal: a primeira componente, com valores mais baixos, corresponde ao ruído; a segunda, centrada em valores mais altos, representa os eventos de sinal (múons).

O critério de decisão consiste em determinar o menor valor de energia acumulada tal que pelo menos 98% dos eventos de sinal sejam aceitos. Esse valor define o limiar de corte, usado para discriminar entre sinal e fundo. Eventos com energia total abaixo desse limiar são classificados como ruído, e acima como múons.

C. Modelos de Aprendizado de Máquina

Modelos de aprendizado de máquina, como redes neurais [8], oferecem uma abordagem alternativa e mais flexível para o problema. Diferentemente dos métodos lineares tradicionais, esses modelos são capazes de identificar padrões não triviais nos sinais amostrados, aprendendo diretamente das

características do pulso, mesmo na presença de ruído não gaussiano. Além disso, redes neurais podem capturar relações de correlação entre diferentes canais da torre, algo difícil de modelar explicitamente em abordagens convencionais baseadas apenas em energia.

Neste estudo, são avaliados dois modelos principais de redes:

1) Perceptron Multicamadas (MLP)

Testamos duas configurações de MLP que recebem como entrada o vetor $\mathbf{x}$:

• E-MLP (Energy-based MLP).

Entrada: escalar com a energia estimada pelo *Optimal Filter* (OF). *Arquitetura:* camada oculta com 10 neurônios (tanh) e saída com 1 neurônio (tanh). *Objetivo:* medir o ganho de desempenho ao refinar uma métrica de energia clássica.

Tabela I: Arquitetura da E-MLP.

Camada	Ativação	Entrada	Saída
hidden (Dense)	Linear	(None, 5)	(None, 5)
inference (Dense)	Linear	(None, 5)	(None, 1)
output (Dense)	Sigmoid	(None, 1)	(None, 1)

• S-MLP (Sample-based MLP).

Entrada: todas as 7 amostras de cada canal concatenadas em $\mathbf{x} \in \mathbb{R}^{7N}$. *Arquitetura:* duas camadas ocultas com 5 e 1 neurônios (ativação linear), seguidas de camada de saída com 1 neurônio (sigmoid). *Objetivo:* Explorar diretamente a o valor de energia digitalizado.

Tabela II: Arquitetura da S-MLP.

Camada	Ativação	Entrada	Saída
hidden (Dense)	Linear	(None, 35)	(None, 5)
inference (Dense)	Linear	(None, 5)	(None, 1)
output (Dense)	Sigmoid	(None, 1)	(None, 1)

2) Rede Neural Convolucional (CNN)

A arquitetura convolucional explora a estrutura bidimensional (tempo $\times$ canal) das amostras digitais. Ela consiste em:

- 1) **Etapa convolucional:** duas camadas Conv2D com ativações ReLU, intercaladas com MaxPooling2D para redução da dimensão espacial;
- 2) **Etapa densa:** após o Flatten, uma camada totalmente conectada com 128 neurônios (ReLU), seguida da saída final com 1 neurônio (Sigmoid).

Essa topologia é muito complexa para ser implementada em FPGA, mas serve como uma demonstração do quão poderosa a classificação pode ser.

Tabela III: Arquitetura da CNN utilizada no estudo.

Camada	Ativação	Entrada	Saída
reshape (Reshape)	-	(None, 5)	(None, 5, 7, 1)
C1 (Conv2D)	ReLU	(None, 5, 7, 1)	(None, 5, 7, 32)
P1 (MaxPooling2D)	-	(None, 5, 7, 32)	(None, 2, 3, 32)
C2 (Conv2D)	ReLU	(None, 2, 3, 32)	(None, 2, 3, 64)
P2 (MaxPooling2D)	-	(None, 2, 3, 64)	(None, 2, 3, 64)
flatten (Flatten)	-	(None, 2, 3, 64)	(None, 384)
dense (Dense)	ReLU	(None, 384)	(None, 128)
output (Dense)	Sigmoid	(None, 128)	(None, 1)

D. Treinamento e Avaliação

A avaliação dos modelos foi realizada utilizando validação cruzada com 5 folds, onde em cada iteração 80% dos dados foram utilizados para treinamento e 20% para teste, respeitando o balanceamento entre as classes de sinal e ruído.

Como métrica principal de desempenho, adotou-se a Falso Alarme (F_A) medida no ponto de operação com Probabilidade de Detecção (P_D) fixada em 98%, refletindo os requisitos do sistema de filtragem do experimento.

Essas abordagens fornecem diferentes pontos de equilíbrio entre desempenho e custo de implementação em FPGA, permitindo escolhas adaptadas às restrições de cada cenário no TileCal.

IV. DESCRIÇÃO DOS DADOS

Os experimentos deste estudo foram conduzidos com dados reais adquiridos em 2024.

A. Seleção de Eventos de Sinal

O conjunto de eventos de sinal é obtido da coincidência de eventos entre os pulsos digitais registrados no TileCal e a reconstrução de múons realizada pelo sistema offline do ATLAS. Foram selecionados eventos com base em seu Momento Transverso (p_T) e no critério de aprovação de algoritmos de reconstrução *offline*. Para cada evento no conjunto de dados de múon, seu *EventNumber* foi comparado aos eventos salvos no *dataset* do TileCal. Caso ocorra a coincidência, as leituras dos canais com as coordenadas correspondentes são salvas.

Algoritmo 1: Seleção de eventos de sinal a partir da reconstrução de múons

Entrada: $File_{In} \leftarrow$ Conjunto de eventos do detector

Saída: $File_{Out} \leftarrow$ Eventos classificados como sinal

```

1 para cada evento E em  $File_{In}$  faça
2   para cada candidato a múon C em E faça
3      $F_1 \leftarrow p_{TC} > 20\text{GeV}$  (limiar de  $p_T$ )
4      $F_2 \leftarrow \text{likelihood} == \text{tight}$  (seleção restritiva)
5     se  $F_1 \wedge F_2$  então
6       Adicionar C em  $File_{Out}$ 
7   fim
8 fim
9 fim
```

B. Construção do Conjunto de Ruído

Para compor o conjunto de fundo, foram utilizadas leituras aleatórias do detector. Por não estarem associadas a nenhuma reconstrução de múon, esses eventos representam o ruído de fundo típico do detector nas mesmas condições em que os sinais de interesse foram adquiridos. Essa abordagem garante que a tarefa de classificação enfrente os desafios reais da separação entre ruído e sinal em um cenário experimental autêntico.




Figura 3: Histograma de p_T dos eventos selecionados. A distribuição começa em 20 GeV, como esperado. O pico em 25 GeV se deve aos algoritmos de seleção que por padrão descartam eventos abaixo desse limiar.

C. Preparação dos Dados para Treinamento

O conjunto completo foi balanceado entre as duas classes e segmentado para treinamento e teste por meio de validação cruzada com 5 *folds*. Cada pulso digital foi normalizado individualmente, dividindo-se todas as amostras pelo valor máximo registrado no pulso, onde o maior valor é sempre igual a 1. Todas as etapas de pré-processamento (como organização dos vetores de entrada, limpeza e normalização) foram aplicadas de maneira uniforme em todos os conjuntos, respeitando a estrutura física dos canais do TileCal.




Figura 4: Amplitude do pulso de cada canal para uma mesma torre em um evento de múon.

V. RESULTADOS

Na análise dos resultados, a avaliação do método baseado em cortes rígidos é realizada considerando separadamente cada uma das torres de trigger (*Trigger Towers* — TTs). Nesse cenário, as 20 torres do detector (10 com valores negativos de η , no lado C, e 10 com valores positivos de η , no lado A) serão tratadas individualmente, permitindo avaliar o desempenho específico do método para diferentes regiões do TileCal.

No caso das redes neurais (E-MLP, S-MLP e CNN), cada rede será treinada e avaliada considerando pares simétricos de

torres em relação ao centro do detector. Assim, torres com o mesmo valor absoluto de η — como TT01A e TT01C — compartilham o mesmo modelo. Dessa forma, os resultados apresentados para as redes refletem o desempenho por módulo da posição azimutal, independentemente do lado (A ou C) da torre.

Além disso, todas as análises desconsideram a região central de transição entre o barril e o barril estendido, conhecida como *crack region*, correspondente ao intervalo $0,8 < |\eta| < 1,0$. Essa região apresenta baixa instrumentação e resposta instável, sendo tradicionalmente excluída de análises de desempenho.

Os dados são sempre divididos em 5 folds. Os pontos nos gráficos são o valor médio calculado para as 5 distribuições, e as barras de erro seu desvio padrão.

A. Critério de Avaliação

Para cada torre, o desempenho é avaliado por meio da curva ROC (*Receiver Operating Characteristic*), que relaciona a taxa de detecção verdadeira (PD) com a taxa de falso alarme (FR) em função do limiar de decisão aplicado à saída da rede.




Figura 5: Curva ROC da TT10 com o modelo E-MLP. O ponto de operação adotado neste estudo, comum a todas as torres e modelos, corresponde à posição da curva em que a probabilidade de detecção atinge 98%. O valor de FR associado a esse ponto é então registrado como métrica final de desempenho.

B. Desempenho do Método Cut-Based por Torre

Como linha de base para a comparação, foi avaliado inicialmente o desempenho do método baseado em corte rígido de energia. A Figura 6 mostra a taxa de falso alarme obtida individualmente para cada torre de trigger (TT), considerando os lados A e C separadamente.




Figura 6: Taxa de falso alarme (FR) para cada torre de trigger com o método cut-based, considerando PD = 98%.

Nas regiões centrais do TileCal ($|\eta| < 0,7$), o método apresenta taxas de falso alarme ao redor de 5% em praticamente todas as torres. Contudo, à medida que nos aproximamos da transição entre o Long Barrel e o Extended Barrel — região conhecida como *crack* ($0,8 < |\eta| < 1,0$) — o cenário muda drasticamente.

A torre TT10, localizada exatamente no início do Extended Barrel, exibe uma taxa de falso alarme de 35%, o que evidencia a degradação do poder de separação entre sinal e ruído nessa região. De forma geral, as torres situadas no Extended Barrel apresentam FRs consistentemente elevadas, tornando o método cut-based inadequado para essas regiões se adotado isoladamente. Essa torre será usada como parâmetro da torre mais ruidosa ao longo das avaliações.

C. Resultados com E-MLP

A rede E-MLP utiliza como entrada a energia estimada pelo OF para cada canal. Ao depender de uma reconstrução linear otimizada para pulsos com forma idealizada, o modelo pode herdar erros sistemáticos e perder parte da variabilidade informativa presente nos dados brutos.




Figura 7: Taxa de falso alarme por torre com PD = 98%. No Long Barrel, observa-se redução da FR para valores entre 1% e 3%, em comparação aos 5% ou mais do corte rígido. Já no Extended Barrel, o valor de FR na TT10 é reduzido de $35 \pm 5\%$ para $17 \pm 7\%$.

Os resultados sugerem que, embora a E-MLP seja capaz de capturar padrões úteis mesmo com entrada reduzida, seu desempenho é limitado pelas imprecisões associadas à estimativa de energia pré-processada. Isso reforça a necessidade de utilizar modelos que operem diretamente sobre as amostras brutas do sinal, como nas arquiteturas S-MLP e CNN, discutidas a seguir.

D. Resultados com CNN

Após verificar que o uso de redes neurais pode contribuir significativamente para a redução da taxa de falso alarme, passamos a avaliar o desempenho de uma arquitetura mais expressiva: uma rede neural convolucional (CNN), projetada para explorar diretamente a estrutura espaço-temporal dos pulsos amostrados.

Diferentemente da E-MLP, que opera sobre a energia estimada pelo *Optimal Filter*, a CNN utiliza como entrada os próprios valores de amplitude do pulso, preservando integralmente a informação bruta capturada pelo detector. A arquitetura, descrita anteriormente, possui múltiplas camadas convolucionais e densas, e não foi projetada com restrições de complexidade. O objetivo neste caso é investigar o potencial máximo de separação entre sinal e ruído, sem considerar a viabilidade de implementação em hardware.




Figura 8: Taxa de falso alarme por torre, com PD fixada em 98%. Os resultados obtidos com a CNN representam o melhor desempenho entre todos os métodos avaliados. No Long Barrel, a FR atinge valores da ordem de $0,01 \pm 0,01\%$. Em quase todas as torres centrais, o classificador atinge uma separação quase perfeita entre os pulsos de múon e o ruído de fundo.

As únicas torres com taxas de falso alarme ainda relevantes foram aquelas nas bordas do detector, onde a separação física entre o Long Barrel e o Extended Barrel impõe desafios adicionais. Na TT10, que se destacou como a torre mais crítica ao longo da análise, a CNN reduziu a FR para $9,3 \pm 2,0\%$.

Esses resultados demonstram que, mesmo nas regiões mais problemáticas, há margem significativa de melhora ao se utilizar arquiteturas capazes de explorar diretamente a forma do pulso e suas correlações entre canais. A CNN serve, portanto, como uma referência de desempenho ideal, contra a qual arquiteturas mais simples e implementáveis podem ser comparadas.

E. Resultados com S-MLP

Considerando que a arquitetura convolucional apresentou desempenho superior, mas com custo computacional elevado e inviável para implementação em hardware como FPGAs, exploramos uma alternativa mais simples: a rede S-MLP.

Diferentemente da E-MLP, que opera sobre uma entrada escalar, a S-MLP recebe diretamente o vetor de amostras de todos os canais da torre, preservando a informação temporal e permitindo o aprendizado de padrões relacionados à forma dos pulsos. Apesar da ausência de convoluções, o modelo consegue, de forma notável, capturar características discriminantes suficientes para atingir excelente desempenho.




Figura 9: Taxa de falso alarme obtida com a S-MLP em cada torre, mantendo a probabilidade de detecção em 98%. No Long Barrel, o modelo atinge uma FR média de aproximadamente $0,11 \pm 0,02\%$, desempenho muito próximo ao da CNN. Isso indica que a maior parte da capacidade de separação entre sinal e ruído pode ser alcançada mesmo com uma arquitetura relativamente leve, desde que operando diretamente sobre os dados brutos.

Na TT10, a S-MLP registra uma FR de $10,65 \pm 2,29\%$, valor semelhante ao da CNN, o que reforça a robustez do modelo mesmo em regiões tradicionalmente problemáticas.

Os resultados da S-MLP indicam que é possível atingir um compromisso muito favorável entre desempenho e complexidade, com uma rede que ainda pode ser viável para implementação em FPGAs, especialmente com otimizações adicionais. A arquitetura representa, portanto, uma solução prática com desempenho próximo ao ideal estabelecido pela CNN.

VI. CONCLUSÕES

Neste trabalho, é avaliado o uso de redes neurais para a identificação de múons no TileCal do experimento ATLAS, com o objetivo de reduzir a taxa de falso alarme em comparação ao método tradicional baseado em corte rígido de energia. São testadas quatro abordagens: o método cut-based, a rede E-MLP com entrada escalar, a S-MLP com amostras brutas e a CNN convolucional.

Os resultados mostram que, mesmo com uma entrada limitada, a E-MLP consegue reduzir significativamente a taxa de falso alarme, especialmente no Long Barrel. No entanto, o uso da energia reconstruída como entrada introduz limitações impostas pelo próprio *Optimal Filter*, o que restringe o desempenho da rede em regiões mais críticas do detector.

A arquitetura CNN, por outro lado, apresenta o melhor desempenho entre todos os modelos, com FR inferior a $0,2\%$ no Long Barrel e cerca de 9% na torre mais desafiadora (TT10). No entanto, sua complexidade inviabiliza a implementação direta em FPGAs, o que limita seu uso em ambientes de filtragem em tempo real.

Como alternativa intermediária, a rede S-MLP é capaz de atingir desempenho comparável ao da CNN com complexidade substancialmente menor. Com FR de $0,11\%$ no LB

e aproximadamente 10,6% na TT10, a S-MLP se mostra promissora como uma solução prática, balanceando eficiência e viabilidade de implementação.

Esses resultados demonstram que redes neurais, mesmo com arquiteturas simples, podem ser utilizadas para melhorar significativamente o desempenho da filtragem de múons no TileCal. A substituição do filtro casado por modelos treináveis com entrada direta das amostras permite explorar melhor a forma do pulso, além de oferecer flexibilidade para adaptação às diferentes regiões do detector.

Tabela IV: Comparação entre as abordagens avaliadas, com FR média no Long Barrel (LB), na torre TT10 e viabilidade de implementação em FPGA.

Abordagem	FR no LB [%]	FR na TT10 [%]	Implementável
Cut-Based	$6,94 \pm 2,00$	$35,67 \pm 1,74$	Sim
E-MLP	$1,65 \pm 1,24$	$17,26 \pm 6,57$	Sim
CNN	$0,01 \pm 0,01$	$9,30 \pm 2,02$	Não
S-MLP	$0,11 \pm 0,02$	$10,65 \pm 2,23$	Sim

Trabalhos Futuros

Como continuação deste estudo, os seguintes tópicos serão investigados:

- *Análise de resiliência ao pile-up*: avaliar o desempenho dos modelos em cenários com diferentes níveis de empilhamento de sinal, verificando sua robustez frente ao aumento de ocupação do detector na transição para o *High-Luminosity LHC* (HL-LHC)
 - *Exploração de novas seleções de canais*: atualmente, todos os canais da torre são utilizados como entrada para os
- [6] T. C. A. Paschoalin and A. d. O. Almeida, “Estudo de um Método para Detecção de Múons no Experimento ATLAS Baseado em Rede Neural Convolutacional.”

modelos. Pretende-se investigar se a restrição às células do tipo D — conhecidas por sua maior sensibilidade ao sinal de múons — pode melhorar a eficiência da classificação.

- *Comparação com abordagens tradicionais*: enquanto a TMDB utiliza apenas as células D5 e D6, esta proposta visa avaliar o impacto de considerar todas as células D distribuídas ao longo do calorímetro, buscando uma cobertura mais ampla e uniforme.

REFERÊNCIAS

- [1] A. Collaboration, “The ATLAS Experiment at the CERN Large Hadron Collider,” *JINST*, vol. 3, p. S08003, 2008. [Online]. Available: <https://cds.cern.ch/record/1129811>
- [2] “ATLAS tile calorimeter: Technical Design Report,” 1996, place: Geneva Series: Technical design report. ATLAS. [Online]. Available: <https://cds.cern.ch/record/331062>
- [3] “TileCal Trigger Towers.” [Online]. Available: <https://hep.uchicago.edu/atlas/tilecal/level1/geometry.html>
- [4] V. A. Ferraz, “Detecção online eficiente de eventos raros utilizando detectores finamente segmentados,” Mar. 2018, accepted: 2019-09-10T17:11:36Z Publisher: Universidade Federal do Rio de Janeiro. [Online]. Available: <http://pantheon.ufrj.br/handle/11422/9430>
- [5] E. Fullana, J. Castelo, V. Castillo, C. Cuenca, A. Ferrer, E. Higón, C. Iglesias, A. Munar, J. Poveda, A. Ruiz-Martinez, B. Salvachúa, C. Solans, R. Teuscher, and J. Valls, “Optimal Filtering in the ATLAS Hadronic Tile Calorimeter,” 2005, place: Geneva. [Online]. Available: <https://cds.cern.ch/record/816152>
- [7] B. S.-M. Peralva, “Reconstrução de energia para calorímetros finamente segmentados,” Sep. 2015, accepted: 2015-12-16T15:15:06Z Publisher: Universidade Federal de Juiz de Fora. [Online]. Available: <https://repositorio.ufjf.br/jspui/handle/ufjf/243>
- [8] S. S. Haykin, *Neural Networks and Learning Machines*. Prentice Hall, 2009, google-Books-ID: K7P36IKzI_QC.