

Detecção e Estimação de Sinais para Operação do Calorímetro de Telhas do ATLAS no HL-LHC

Guilherme I. Gonçalves, Bernardo S. Peralva, Gustavo B. Libotte, Luciano M. de Andrade Filho, Augusto S. Cerqueira e José Manoel de Seixas

Resumo—Métodos inovadores para estimação de energia e detecção de sinais em calorimetria de altas energias são explorados, com foco na atualização do Calorímetro de Telhas (TileCal) do experimento ATLAS para o High-Luminosity Large Hadron Collider (HL-LHC), cuja operação está prevista para 2029. O programa de atualização do TileCal impõe mudanças na forma de processar o sinal visando atender aos novos requisitos de operação do experimento. Desta forma, este trabalho propõe o emprego de um método linear baseado no método dos mínimos quadrados assistido por um modelo não linear, implementado por uma rede neural perceptron multicamadas. Os resultados mostram melhorias significativas na redução do erro de estimação e na classificação de sinais, especialmente sob altas taxas de ocupação do detector, como é previsto na operação do HL-LHC.

Palavras-Chave—estimação de sinais, filtragem ótima, aprendizagem de máquina, calorimetria de altas energias.

I. INTRODUÇÃO

A instrumentação para física experimental de altas energias é uma área desafiadora, marcada pela complexidade dos fenômenos investigados e pelas barreiras tecnológicas. Um aspecto notável é a aquisição de milhares de sinais em taxas extremamente altas, um problema que este trabalho visa abordar [13]. Sistemas de calorimetria de altas energias são cruciais para o sucesso destes experimentos uma vez desempenham a função de absorver e amostrar a energia de partículas incidentes, fornecendo dados essenciais para a identificação de partículas e a seleção de eventos [19].

Tipicamente, em calorimetria de altas energias, camadas de material passivo são intercaladas com material ativo, frequentemente segmentadas em milhares de células para oferecer uma resolução espacial detalhada ao detector [11]. Os sinais gerados por cada célula são conformados e digitalizados por eletrônica dedicada, permitindo a reconstrução das propriedades das partículas. O fenômeno de empilhamento de sinais, comum em experimentos de alta taxa de eventos, adiciona complexidade e incerteza à reconstrução do sinal, tornando-se um tópico de grande relevância nesta área de pesquisa [4], [16].

O CERN, pioneiro em física de altas energias, tem contribuído para descobertas significativas, como a observação do

Guilherme I. Gonçalves, e-mail: ggoncalves@iprj.uerj.br; Bernardo S.M. Peralva, email: bernardo@iprj.uerj.br, Gustavo B. Libotte, email: gustavo-libotte@iprj.uerj.br, Departamento de Modelagem Computacional, Universidade do Estado do Rio de Janeiro, Nova Friburgo-RJ. Luciano M. de Andrade Filho, Augusto S. Cerqueira, Universidade Federal de Juiz de Fora, MG, email: luciano.andrade@ufjf.br, augusto.santiago@ufjf.br. José M. de Seixas, email: seixas@lps.ufjf.br, COPPE/Poli, Universidade Federal do Rio de Janeiro, RJ.

Bóson de Higgs em 2012 [6], e a origem da World Wide Web [2]. Desde a década de 1930, aceleradores de partículas têm sido cruciais no estudo da física de partículas, com o *Large Hadron Collider* (LHC), o maior e mais energético acelerador do mundo, atingindo energias de até 13 TeV [10], [18]. O LHC colide diferentes partículas, como prótons e íons de chumbo, a uma taxa de 40 MHz, nos quatro principais experimentos: ATLAS, CMS, ALICE e LHCb. O ATLAS, um experimento de propósito geral, utiliza tecnologias avançadas e um sistema de calorimetria de última geração para medir a energia das partículas em colisões, determinando suas propriedades-chave [5].

Em 2018, o detector ATLAS iniciou um ambicioso projeto de pesquisa em física, com o objetivo de explorar processos raros. Esse empreendimento requer um aumento considerável na coleta de dados, impulsionado pelo incremento na luminosidade integrada, que está diretamente relacionada à densidade do feixe de prótons. Para alcançar esse objetivo, foi planejada e executada uma ampla atualização do detector e sistemas associados em duas fases. A Fase I, concluída em 2021, introduziu melhorias no detector de múons e em toda a cadeia de *trigger* e aquisição de dados [3]. Com uma luminosidade integrada sem precedentes, o LHC migrará para o *High-Luminosity LHC* (HL-LHC), exigindo uma Fase II de atualizações para o ATLAS que incluirá uma reformulação dos sistemas de calorimetria e múons para enfrentar os desafios de operação em alta luminosidade [1].

O aumento na taxa de eventos e luminosidade apresenta novos desafios em eletrônica e processamento de sinais. Com o aumento da luminosidade, a probabilidade de incidência de sinais no mesmo canal de leitura do sistema de calorimetria do ATLAS também aumenta, criando o efeito de empilhamento de sinais devido à resposta do calorímetro ser mais lenta que o intervalo entre colisões, conforme ilustrado pela Figura 1. Durante a operação atual, espera-se que o LHC alcance de 50 a 80 interações por colisão em média, a cada 25 ns. Após a Fase II, o LHC pretende atingir valores ainda mais altos, possivelmente até 200 interações por colisão. Este trabalho aborda o problema da estimação de energia de partículas no calorímetro de Telhas do ATLAS (TileCal) sob condições de alta luminosidade previstas para os próximos anos de operação do LHC [8], [9]. O método proposto se beneficia do poder computacional e das capacidades de aprendizado adaptativo das redes neurais para aprimorar a precisão dos métodos de estimação lineares comumente utilizados.

A próxima seção descreve as estratégias utilizadas neste trabalho para estimação de sinais em calorimetria de altas energias. Na sequência, na Seção 3, os resultados para aplica-

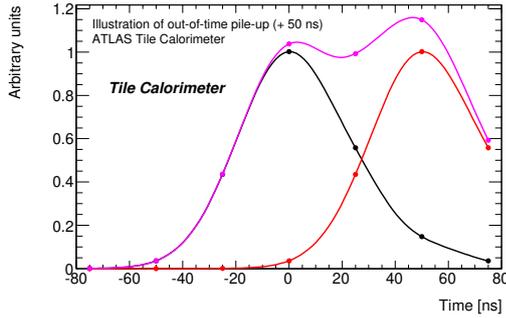


Fig. 1: Ilustração do efeito de empilhamento de sinais no TileCal.

ção no calorímetro de telhas do ATLAS são apresentados. As discussões e trabalhos futuros são comentados na Seção 4.

II. ESTRATÉGIAS DE ESTIMAÇÃO DE ENERGIA

Em sistemas de calorimetria convencionais, os sinais adquiridos no detector passam por uma série de etapas, incluindo condicionamento, modelagem e conversão digital, antes de serem transmitidos para etapa de reconstrução do sinal. Posteriormente, são empregados filtros digitais para determinar a amplitude real do pulso analógico, que está diretamente relacionada à energia depositada no detector.

A. Considerações iniciais

Suponha uma sequência de sinais digitais \mathbf{s} onde, no instante j , cada amostra pode ser expressa como $s^{(j)} = Ag^{(j)} + \sigma^{(j)}$, desconsiderando-se desvios de fase ou deslocamentos de linha de base. Aqui, A é a amplitude do sinal recebido, $g^{(j)}$ é uma amostra do pulso de referência e $\sigma^{(j)}$ é um ruído aditivo, para $j = 1, \dots, M$, onde M é o número de eventos observados. Consideramos pulsos de referência periódicos, cobrindo todos os instantes de tempo M . Além disso, assumimos a existência de uma matriz \mathbf{H} de dimensão $N \times p$. Para uma quantidade arbitrária p de observações contíguas do sinal, podemos organizar o conjunto de amostras tomando $N = M/p$, criando assim “janelas” com tamanho p de dados sequenciais. Cada uma dessas janelas de dados pode compor as linhas da matriz \mathbf{H} . É importante notar que o cálculo de N pode resultar em $M = Np + d$, com $d > 0$. As amostras d , presentes no início e no final da aquisição, são descartadas pois não possuem um pulso completo associado às mesmas. Vale ressaltar que o número M de sinais corresponde a um valor muito superior a esses d eventos. Portanto, esta estratégia não causa prejuízo às análises de eficiência propostas neste trabalho.

Na física de altas energias, a energia do sinal de interesse é avaliada pela estimativa da amplitude do pulso captado pelo sistema de calorimetria. Neste contexto, suponha que temos um conjunto de M valores de amplitude $\mathbf{X} = (X_1, \dots, X_j, \dots, X_M)^\top$ associados aos eventos observados. Podemos tomar as amplitudes $\mathbf{x} = (x_1, \dots, x_i, \dots, x_N)^\top$ correspondentes aos valores centrais de cada janela de \mathbf{X} se a matriz for convenientemente reorganizada como uma matriz $N \times p$, seguindo um procedimento semelhante ao

adotado para compor \mathbf{H} . Assim, podemos afirmar que um sinal $\mathbf{a} = (a_1, \dots, a_i, \dots, a_N)^\top$, puramente determinístico, depende de um conjunto desconhecido de parâmetros $\boldsymbol{\theta} = (\theta_1, \dots, \theta_k, \dots, \theta_p)^\top$ para que a relação $\mathbf{a} = \mathbf{H}\boldsymbol{\theta}$ seja válida, dado que \mathbf{H} corresponde a uma matriz não-singular.

B. Método de Mínimos Quadrados

O Método do Filtro Ótimo (OF) [4] é amplamente utilizado em calorímetros modernos para minimizar a variância do ruído utilizando a forma do pulso de referência. O sinal de entrada é modelado como a soma do pulso de referência, ruído, fase do sinal e pedestal. O OF estima a amplitude do sinal por meio de uma soma ponderada dos valores amostrados em uma janela de leitura, calculando os coeficientes do filtro com base na série de Taylor de primeira ordem e garantindo a imparcialidade do estimador. No entanto, nas novas condições operacionais do HL-LHC, o desempenho do OF é degradado devido à dependência do pulso de referência, distorcido pelo empilhamento de sinais, e ao modelo de dados contínuo (*free-running*) da nova eletrônica [12]. Assim, não existem métodos de estimação comissionados para essa nova eletrônica, tornando este trabalho inédito e sem comparações diretas com métodos preexistentes.

Para minimizar a diferença entre \mathbf{x} e \mathbf{a} , um estimador de mínimos quadrados $\hat{\boldsymbol{\theta}}$ pode ser obtido minimizando a soma dos quadrados dos erros $\mathbf{e} = \mathbf{x} - \mathbf{a}$, o que é equivalente a minimizar $(\mathbf{x} - \mathbf{H}\boldsymbol{\theta})^\top (\mathbf{x} - \mathbf{H}\boldsymbol{\theta})$. Normalmente, o número N de observações é maior que o número p de incógnitas, o que pode levar a $\mathbf{H}\boldsymbol{\theta} = \mathbf{x}$ ser inconsistente. Provavelmente, não haverá uma escolha de $\boldsymbol{\theta}$ que se ajuste perfeitamente aos dados \mathbf{x} , significando que \mathbf{x} provavelmente não será uma combinação linear das colunas de \mathbf{H} . No entanto, este método não faz suposições probabilísticas sobre os dados \mathbf{x} , tornando-o aplicável tanto para ruídos Gaussianos quanto não Gaussianos.

Obter um estimador de mínimos quadrados $\hat{\boldsymbol{\theta}}$ que minimize \mathbf{e} é equivalente a encontrar um ponto $\mathbf{H}\boldsymbol{\theta}$ mais próximo de \mathbf{x} no espaço coluna. Assim, o vetor de erro \mathbf{e} deve ser ortogonal a cada coluna $\mathbf{h}_1, \dots, \mathbf{h}_p$ de \mathbf{H} , o que é equivalente a $\mathbf{h}_k^\top (\mathbf{x} - \mathbf{H}\hat{\boldsymbol{\theta}}) = 0$ para $k = 1, \dots, p$. Supondo que a matriz \mathbf{H} tem posto completo p , calcular um estimador de mínimos quadrados $\hat{\boldsymbol{\theta}}$ envolve calcular

$$\hat{\boldsymbol{\theta}} = (\mathbf{H}^\top \mathbf{H})^{-1} \mathbf{H}^\top \mathbf{x}, \quad (1)$$

onde a igualdade $\mathbf{H}^\top \mathbf{H}\hat{\boldsymbol{\theta}} = \mathbf{H}^\top \mathbf{x}$ é conhecida como a *equação normal*. A matriz $\mathbf{H}^\top \mathbf{H}$ é invertível quando as colunas de \mathbf{H} são linearmente independentes. Este método, ao reduzir o problema para a otimização por meio de um sistema de equações lineares, fornece uma maneira robusta e eficiente de estimar parâmetros em uma ampla gama de aplicações, desde processamento de sinais até análise estatística de dados [15]. Testes preliminares recentes mostraram a viabilidade de aplicação no contexto do calorímetro TileCal [17].

C. Mínimos Quadrados assistido por Rede Neural Perceptron Multicamadas

Para acessar componentes de ordem superior inalcançáveis por modelos lineares, uma rede neural Perceptron Multicamadas (MLP) pode ser usada como um corretor não linear dos pesos estimados pelo método de mínimos quadrados. A MLP funciona como uma ferramenta de mapeamento não linear, ajustando os pesos estimados para melhorar a precisão das estimativas [14].

Uma MLP é uma arquitetura de rede neural artificial com múltiplas camadas, incluindo camadas de entrada, ocultas e de saída. Cada camada é composta por neurônios interconectados, onde cada neurônio processa entradas ponderadas por meio de uma função de ativação para produzir uma saída. Nesta aplicação, a estratégia envolve treinar uma rede neural MLP para aprender uma função não linear que mapeie conjuntos de amostras observadas \mathbf{x} em resíduos preditos, que são as diferenças entre a amplitude estimada e seu valor real. O conceito central desta metodologia é melhorar a estimativa de Mínimos Quadrados \hat{A}_{LS} adicionando uma correção derivada da MLP \hat{e}_{MLP} , conforme estabelecido na Equação 2. Esse processo é representado visualmente na Figura 2.

$$\hat{A}_{corrected}(\mathbf{x}) = \hat{A}_{LS}(\mathbf{x}) + \hat{e}_{MLP}(\mathbf{x}) \quad (2)$$

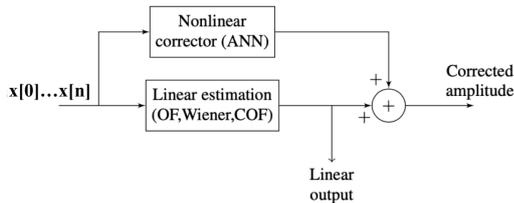


Fig. 2: Estratégia proposta para corrigir não-linearidades introduzidas pelo empilhamento de sinal no cenário de atualização do TileCal.

III. RESULTADOS

Conjuntos de dados sintéticos foram produzidos usando o simulador oficial do TileCal, conhecido como *Tile Pulse Simulator*, que está implementado na infraestrutura de software do ATLAS, Athena [7], e que simula a nova arquitetura de dados *free-running* (ou *streaming*) a ser implementada pela nova eletrônica do TileCal para operação no HL-LHC.

Visando cobrir uma ampla gama de intensidades de empilhamento de sinais, foram gerados vários conjuntos de dados simulando um número médio de interações por cruzamento de feixe $\langle \mu \rangle$ variando de 10 a 200. Cada conjunto de dados compreende 1 milhão de eventos para cada célula, módulo e canal do TileCal, totalizando aproximadamente 64 milhões de amostras temporais para cada célula em cada conjunto de dados. Esta abordagem abrangente garante um conjunto de dados robusto, capaz de simular as diversas condições esperadas nas futuras operações de alta luminosidade. A amplitude verdadeira varia de 0 a 4095 contagens de ADC e segue uma distribuição de Poisson, com sua média correlacionando-se diretamente ao valor de $\langle \mu \rangle$. De forma simplificada, do ponto de vista dos dados, para cada célula, módulo e canal,

o simulador gera duas séries numéricas com 1 milhão de entradas cada: amostras digitais e amplitudes verdadeiras.

Para determinar a ordem ótima do filtro LS em termos operacionais, foi realizado um estudo focado em eventos de alto ganho da célula EBA A12-L, significativamente impactada pelo empilhamento de sinais. Foram selecionados 100.000 eventos para cada $\langle \mu \rangle$, divididos em 80% para design do estimador LS e 20% para testes. A ordem do estimador LS foi ajustada de 5 a 31 em incrementos de 2, e o erro de estimação foi calculado como a diferença entre as amplitudes estimada e verdadeira dos eventos do conjunto de teste. A Figura 3 mostra o Erro Médio Quadrático (RMS) em função da ordem do estimador, indicando que a ordem 15 do filtro LS é ideal, oferecendo desempenho satisfatório e uso eficiente de recursos de hardware, com variações mínimas de eficiência (menos de 2 contagens ADC) nos níveis de ocupação considerados.

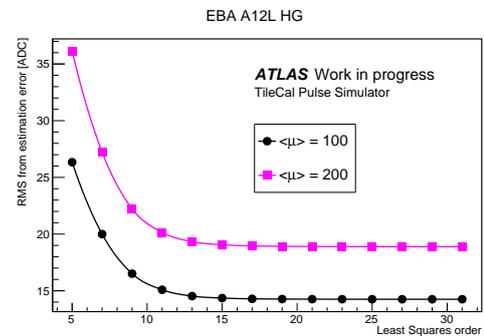


Fig. 3: Relação entre a ordem do filtro LS e o RMS do erro de estimação para $\langle \mu \rangle = 100$ e $\langle \mu \rangle = 200$.

Após definir a ordem do filtro, o desempenho foi avaliado em termos da média e do desvio padrão do erro de estimação da amplitude, considerando diferentes níveis de ocupação e todas as células do calorímetro, exceto a camada E.

A Figura 4 compara o desempenho da reconstrução de energia usando o conjunto de dados $\langle \mu \rangle = 200$, calculando a diferença entre as energias reconstruída e verdadeira. Como esperado, a camada A apresenta os maiores erros devido à sua proximidade com o ponto de colisão. As barras horizontais na figura mostram a cobertura em η para cada célula, fornecendo *insights* sobre a distribuição espacial da precisão da estimação ao longo do calorímetro.

O objetivo agora é mitigar as limitações do método de Mínimos Quadrados (LS) causadas pelo empilhamento de sinais, utilizando uma rede neural corretiva para absorver os componentes não lineares do ruído de empilhamento e melhorar a qualidade da estimação. Esta abordagem visa minimizar o erro de LS, permitindo que a rede neural preveja o erro de LS para um sinal de entrada específico e o subtraia da estimativa gerada, corrigindo o valor final.

Para equilibrar complexidade e viabilizar a implementação tais métodos em circuitos *field programmable gate array* (FPGA), cujos recursos de hardware são limitados, foi escolhida uma MLP com função de ativação ReLU, que pode ser tabulada. A dimensão de entrada da rede é igual à ordem do LS, com 15 nós de entrada, e a dimensão de saída consiste em um único neurônio com ativação linear. Redes MLP com 1 e 2

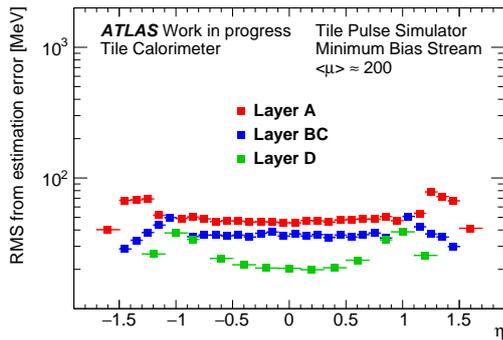


Fig. 4: Análise do desempenho do método de Mínimos Quadrados em todo o calorímetro: visualização do erro de estimativa e cobertura em η .

camadas escondidas e diferentes números de neurônios foram testadas para determinar a arquitetura ideal. Concentrando-se nas condições de operação previstas para o upgrade do HL-LHC, foram selecionados os conjuntos de dados com taxas médias de interação de $\langle \mu \rangle = 100$ e $\langle \mu \rangle = 200$ para treinar as redes, utilizando validação cruzada k-fold com 10 dobras. Concluiu-se que uma única camada escondida com 7 neurônios generaliza efetivamente o treinamento.

A Tabela I resume os parâmetros da arquitetura final da rede MLP corretiva. Com a arquitetura definida, uma análise de desempenho foi conduzida para avaliar as melhorias na redução do erro de estimativa LS ao introduzir a correção não linear. Esta análise comparou dois métodos: LS padrão e LS aprimorado pela rede corretiva (LS+MLP).

TABELA I: Parâmetros finais da rede MLP corretiva.

Parâmetro	Valor
Dimensão de Entrada	15
Dimensão de Saída	1
Número de Camadas Escondidas	1
Número de Neurônios na Camada Escondida	7
Função de Ativação na Camada Escondida	ReLU
Função de Ativação na Saída	Linear

Os histogramas de erro da Figura 5 indicam que a MLP reduz significativamente a cauda negativa gerada pelo LS. A Tabela II fornece uma análise quantitativa, mostrando reduções de erro RMS de aproximadamente 30%, 65% e 70% para três células distintas do calorímetro.

TABELA II: Análise comparativa da precisão na reconstrução de energia pelos métodos LS e LS+MLP: métricas de média e RMS do histograma do erro de estimativa.

Célula	LS		LS+MLP	
	Média (ADC counts)	RMS	Média (ADC counts)	RMS
EBA A12-R	-0.16	17.49	-0.28	11.93
LBA BC1-R	-0.21	12.17	0.14	4.02
LBA D0	-0.16	7.07	-0.05	2.00

Novamente, expandindo esta análise para todas as camadas do calorímetro, obtém-se uma visão abrangente dos benefícios

da correção não linear dos resíduos de LS. A Figura 6 compara os dois métodos, mostrando que a MLP reduz significativamente o erro de estimativa em todas as células, com melhorias de até 60% na camada A, que se encontra mais próxima ao feixe e, portanto, possui maior ocupação. Estes resultados indicam que a técnica é promissora para minimizar o impacto do empilhamento de sinais na qualidade da reconstrução de energia em calorimetria de alta energia.

A análise a seguir visa avaliar a eficácia dos métodos de Mínimos Quadrados (LS) e LS com correção por rede neural (LS+MLP) na tarefa de classificação de sinais entre eventos de interesse e ruído. Esta classificação é crucial para a seleção eficiente de eventos no LHC, onde apenas uma pequena fração dos eventos registrados são fisicamente significativos.

Para esta análise, foram utilizadas duas métricas principais: taxa de falsos alarmes e taxa de detecção. No TileCal, eventos são categorizados como ruído se a energia verdadeira (conhecida da simulação) for menor ou igual a 5 contagens de ADC, e como eventos de interesse caso contrário.

Após a aplicação dos métodos LS e LS+MLP nos conjuntos de sinal e de ruído, a Curva Característica de Operação do Receptor (ROC) foi utilizada para avaliar a eficiência dos métodos para detecção de sinais. A Figura 7 apresenta as curvas ROC para os métodos LS e LS+MLP, mostrando que o MLP melhora significativamente a qualidade da detecção de eventos em comparação com o método LS.

Para aprofundar a contribuição da rede neural corretiva, a Figura 8 mostra a taxa de detecção para todas as células do TileCal com uma taxa de falso alarme de 10%. Utilizando 100.000 eventos por célula e validação cruzada de 10 dobras, os resultados mostram que o método aprimorado com correção por MLP se destaca pela sua capacidade de distinguir entre sinais significativos e ruído, alcançando um aumento nas taxas de detecção de 15% a 30%. Isso demonstra que a MLP melhora a detecção de eventos e reduz falsos alarmes.

IV. CONCLUSÕES

Este estudo avalia o método de Mínimos Quadrados (LS) para estimativa de energia em calorimetria de alta energia, propondo sua integração com um Perceptron Multicamadas (MLP) para correção neural. Testes iniciais com dados sin-

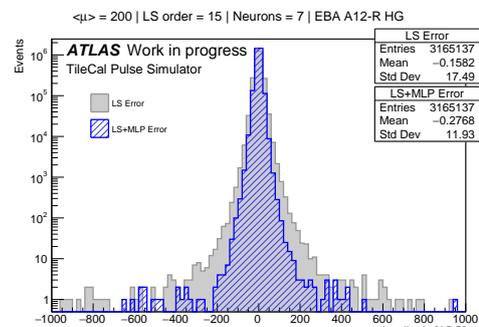


Fig. 5: Histogramas de erro para eventos de alto ganho da célula EBA 12-R correspondentes ao LS (cinza) e LS+MLP (azul), usando o conjunto de dados $\langle \mu \rangle = 200$.

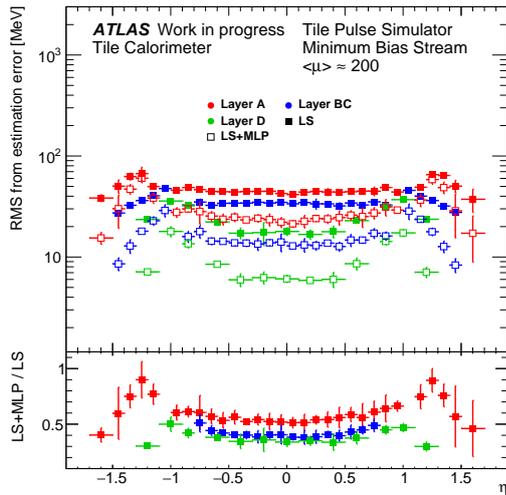


Fig. 6: Análise de desempenho do método de Mínimos Quadrados em todo o calorímetro: visualização do erro de estimação e cobertura em η .

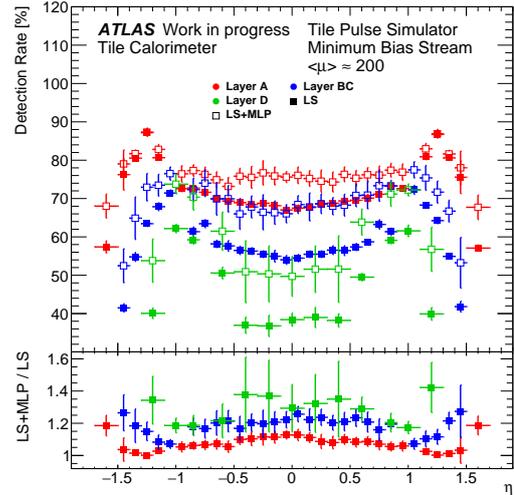


Fig. 8: Análise comparativa das metodologias LS e LS+MLP no calorímetro: taxa de detecção para 10% de falso alarme e visualização da cobertura em η .

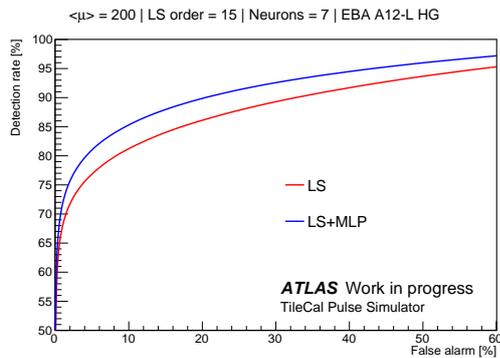


Fig. 7: Curvas ROC para LS (vermelho) e LS+MLP (azul) para a células EBA A12-L do TileCal. As curvas demonstram o equilíbrio entre a taxa de detecção e a taxa de falsos alarmes, com o método LS+MLP mostrando desempenho superior na eficiência de detecção de eventos.

téticos mostram que a combinação LS+MLP melhora significativamente a precisão da estimação, reduzindo os erros RMS de 30% a 70% para diferentes células do calorímetro, e aumenta a eficiência na detecção de eventos em 15% a 30%, especialmente em condições severas de empilhamento de sinais esperadas no HL-LHC. Esses resultados demonstram o potencial da integração de técnicas de aprendizado de máquina para aprimorar a estimação de energia e a detecção de eventos, alinhando-se às futuras demandas operacionais do HL-LHC.

AGRADECIMENTOS

Os autores agradecem a FAPERJ, FAPEMIG, CNPq, CAPES, e RENAFAP pelo apoio. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

REFERÊNCIAS

- [1] G. Apollinari et al. High-Luminosity Large Hadron Collider (HL-LHC): Preliminary Design Report. *CERN Yellow Reports: Monographs*, 2017.
- [2] CERN. *World-Wide Web: invented at CERN*. CERN, Geneva, 1998.
- [3] Zvi Citron. The ATLAS Upgrade Program. Technical report, CERN, Geneva, 2023.
- [4] WE Cleland and EG Stern. Signal processing considerations for liquid ionization calorimeters in a high rate environment. *Nuclear Instruments and Methods in Physics Research Section A*, 338(2-3):467–497, 1994.
- [5] ATLAS Collaboration. The ATLAS Experiment at the CERN Large Hadron Collider. *JINST*, 3:S08003. 437 p, 2008. Also published by CERN Geneva in 2010.
- [6] 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*, 716(1):1–29, 2012.
- [7] ATLAS Collaboration. Athena, April 2019.
- [8] The ATLAS Collaboration. Atlas phase-ii upgrade scoping document. 2020.
- [9] Daniel Eriksson, Steffen Muschter, K Anderson, Christian Bohm, Hossein Kaviani-pour, M Oreglia, and F Tang. A prototype for the upgraded readout electronics of TileCal, 2012.
- [10] Lyndon R Evans and Philip Bryant. LHC Machine. *JINST*, 3:S08001. 164 p, 2008. This report is an abridged version of the LHC Design Report (CERN-2004-003).
- [11] C.W. Fabjan and T. Ludlam. *Calorimetry: Energy Measurement in Particle Physics*. Springer, 2003.
- [12] Esteban Fullana. Optimal filtering and pileup effects in calorimetry at the lhc. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, 566(1):25–29, 2006.
- [13] Dan Green. High rate particle physics experiments. *Annual Review of Nuclear and Particle Science*, 50(1):27–56, 2000.
- [14] Simon Haykin. *Neural Networks: A Comprehensive Foundation*. Prentice Hall PTR, 1998.
- [15] Steven M. Kay. *Fundamentals of Statistical Signal Processing, Volume I: Estimation Theory*. Prentice Hall, 1993.
- [16] Pawel Klimek. Signal pile-up in the tilecal calorimeter. *ATL-TILECAL-PROC-2013-014*, 2013.
- [17] B. S. Peralva. Signal reconstruction in atlas tile calorimeter using run 3 real data and perspectives for the phase-ii operation. In *2023 IEEE Nuclear Science Symposium (NSS MIC RTS)*, pages 1–2, 2023.
- [18] Helmut Wiedemann. *Particle accelerator physics*. Springer, 2015.
- [19] R. Wigmans. *Calorimetry: Energy Measurement in Particle Physics*. International Series of Monographs on Physics. OUP Oxford, 2017.