

Aplicação de redes neurais MLP e CNN para redução de *crosstalk* em dados de simuladores de eventos de física de altas energias

Leandro dos Santos Gama
Grupo de Processamento de
Áudio Digital - GPAD
Departamento de Engenharia
Elétrica e de Computação
Universidade Federal da Bahia
Salvador, Brasil
leandro.gama@ufba.br

Antônio Carlos Lopes Fernandes Jr
Grupo de Processamento de
Áudio Digital - GPAD
Departamento de Engenharia
Elétrica e de Computação
Universidade Federal da Bahia
Salvador, Brasil
antonio.lopes@ufba.br

Eduardo F. de Simas Filho
Departamento de Engenharia
Elétrica e de Computação
Universidade Federal da Bahia
Salvador, Brasil
eduardo.simas@ufba.br

Abstract—High-energy physics event simulators, such as the Lorenzetti Showers Framework, are pivotal in analysis and predictive modeling by reproducing interactions observed in experiments like ATLAS at the LHC. The simulated datasets include calorimetric signals corrupted by electronic noise and various crosstalk components, enabling the development of mitigation strategies and enhanced energy reconstruction. In this work, we evaluate two machine-learning architectures—Multilayer Perceptrons (MLPs) and Convolutional Neural Networks (CNNs)—to reduce crosstalk effects on these simulated signals. Both models prove effective; notably, CNNs achieve determination coefficients (R^2) above 85%, slightly outperforming MLPs. These results underscore the potential of such techniques to improve the quality of simulator-generated calorimetric data and, ultimately, to aid energy measurement analysis and calibration in real high-energy physics experiments.

Index Terms—Crosstalk, machine learning, simulators, ATLAS.

Resumo—Simuladores de eventos de física de altas energias tem se mostrado muito úteis em estratégias de análise e previsão de modelos ao reproduzir as interações observadas em experimentos como o ATLAS, do LHC. Os dados gerados destas ferramentas incluem a modelagem de sinais como *crosstalk* e ruído, permitindo análises para desenvolver estratégias de mitigação dessas interferências e melhorar a reconstrução das energias depositadas nos calorímetros. Neste trabalho, modelos de máquinas de aprendizado, especificamente *Multilayer Perceptrons* (MLPs) e *Convolutional Neural Networks* (CNNs), foram aplicados para reduzir os efeitos do *crosstalk* em conjuntos de dados simulados. Os resultados mostraram que os modelos foram eficazes, com coeficientes de determinação R^2 superiores a 85% nos modelos CNN, ligeiramente mais performáticos que os MLPs, destacando o potencial dessas técnicas para aprimorar a qualidade dos dados gerados por simuladores e, futuramente, contribuir para a análise e calibração de medições em experimentos reais.

Palavras-chave—*Crosstalk*, máquinas de aprendizado, simuladores, ATLAS.

I. INTRODUÇÃO

O estudo da física de altas energias, especialmente em experimentos realizados no *Large Hadron Collider* (LHC), demanda a análise de grandes volumes de dados com alta

precisão [1]. No experimento ATLAS, um dos principais detectores do LHC, os dados obtidos durante as colisões de partículas são essenciais para reconstruir eventos subatômicos e investigar fenômenos fundamentais da matéria. Contudo, interferências eletrônicas como o *crosstalk* — acoplamentos indesejados entre canais de leitura adjacentes — comprometem a fidelidade das medições, prejudicando a estimativa da energia depositada nos detectores [2].

Para mitigar esses efeitos e aprimorar a reconstrução de eventos físicos, o uso de simuladores tem se mostrado uma estratégia promissora. Um destes simuladores é o *Lorenzetti Showers Framework* [3], desenvolvido para modelar com precisão as respostas dos calorímetros do ATLAS frente a eventos simulados, incluindo efeitos como *crosstalk* e ruído. Esses dados sintéticos servem como base para a aplicação de técnicas computacionais voltadas à correção das distorções nos sinais.

Neste contexto, este artigo propõe a aplicação de modelos de aprendizado de máquina supervisionado para reduzir os efeitos de *crosstalk* em sinais simulados. Foram investigados dois tipos de redes neurais artificiais: os *Multilayer Perceptrons* (MLPs) e as *Convolutional Neural Networks* (CNNs). Ambos os modelos foram treinados com dados do simulador *Lorenzetti*, com o objetivo de recuperar os valores reais de energia depositada nas células dos calorímetros, mesmo diante das distorções impostas pelas interferências.

II. EXPERIMENTO ATLAS E SEUS CALORÍMETROS

O experimento ATLAS (*A Toroidal LHC Apparatus*), um dos maiores detectores do LHC, foi projetado para estudar uma ampla gama de fenômenos físicos, desde partículas previstas pelo Modelo Padrão até potenciais novos estados da matéria. Com cerca de 44 metros de comprimento, 25 metros de altura e aproximadamente 7.000 toneladas, o ATLAS é uma estrutura altamente simétrica e segmentada, desenvolvida para cobrir o maior número possível de eventos gerados nas colisões do LHC [8].

A arquitetura do ATLAS é projetada com simetria em relação ao ponto de interação das partículas, o que garante cobertura uniforme e precisa dos eventos de colisão. Seu sistema magnético é composto por um solenoide supercondutor fino, que envolve o detector interno, e por três grandes toróides supercondutores — um no barril central e dois nos *end-caps* — dispostos com simetria azimutal de oito setores ao redor do sistema de calorimetria [9], conforme ilustrado na Figura 1. No núcleo do experimento, o detector interno opera imerso em um campo magnético e é responsável pela identificação de padrões de trajetória, medições de momento das partículas e reconstrução de vértices, além da identificação de elétrons. Esse subsistema combina detectores semicondutores de alta resolução, compostos por sensores de pixels e tiras na parte mais interna, com detectores de palhas (*straw tubes*) na parte externa, os quais são sensíveis à radiação de transição e contribuem para o rastreamento das partículas [10].




Figura 1. Detectores do ATLAS. Fonte: [9]

Entre seus principais subsistemas está o sistema de calorimetria, responsável por medir a energia de partículas carregadas e neutras através da absorção e conversão dessa energia em sinais elétricos. A calorimetria do ATLAS, detalhada na Figura 2, é composta por dois tipos principais de calorímetros: eletromagnéticos e hadrônicos. Os calorímetros eletromagnéticos, baseados em tecnologia de argônio líquido (LAr), têm alta granularidade e são otimizados para medir fótons e elétrons com precisão, cobrindo uma ampla faixa de pseudo-rapidez até $|\eta| = 3,2$ [11].

Já os calorímetros hadrônicos são responsáveis por detectar partículas compostas, como prótons, nêutrons e píons. Eles utilizam diferentes tecnologias dependendo da região: na região central, são usados cintiladores segmentados, enquanto nas extremidades do detector também se faz uso de argônio líquido. Esse conjunto estende a cobertura até $|\eta| = 4,9$, permitindo o registro eficiente de eventos mesmo em regiões mais inclinadas em relação ao feixe [12].

O ATLAS também é equipado com um sofisticado sistema de leitura de dados em camadas hierárquicas (*trigger system*), que filtra os eventos mais relevantes em tempo real. O sistema




Figura 2. Esquemático de estrutura dos calorímetros no ATLAS. Fonte: [12]

de aquisição de dados é altamente sensível às flutuações dos sinais, o que torna a presença de interferências como *crosstalk* um fator crítico para a qualidade das medições [2].

III. EFEITO CROSSTALK

O *crosstalk* é um tipo de interferência eletrônica que ocorre quando o sinal de um canal afeta a leitura de canais vizinhos, provocando distorções nas medições. Em detectores de alta granularidade, como os calorímetros do ATLAS, esse efeito se torna particularmente relevante, dada a proximidade física entre os canais e a alta densidade de elementos eletrônicos [13].

Fisicamente, o *crosstalk* pode ser classificado em três componentes principais: capacitivo, indutivo e resistivo. O acoplamento capacitivo resulta da capacitância parasita entre eletrodos adjacentes, sendo dominante em camadas com alta segmentação, como as tiras do calorímetro eletromagnético LAr. Estima-se que esse tipo de interferência possa atingir até 7% da amplitude do sinal original [14]. O acoplamento indutivo, por sua vez, é causado por campos magnéticos gerados por correntes oscilantes, afetando especialmente as camadas intermediária e posterior dos calorímetros. Já o acoplamento resistivo ocorre devido a caminhos elétricos compartilhados, principalmente entre a camada de tiras e a camada intermediária, com menor magnitude, mas ainda relevante para medições precisas [15].

A intensidade do *crosstalk* tende a decair com a distância entre as células, sendo mais pronunciada nas vizinhanças imediatas. Essa característica, associada à geometria dos calorímetros, reforça a necessidade de estratégias robustas de correção. No contexto do ATLAS, duas medidas são comumente utilizadas para quantificação do efeito: *peak-peak*, que fornece um limite superior da interferência ao comparar os




Figura 3. Formas de onda genéricas de um sinal pulsado e seu efeito de crosstalk. Fonte: [15]

picos máximos do sinal pulsado $\text{WavePeak}(T_{\max})$ e do sinal de interferência $X_{\max}$, obtendo-se a razão $X_{\max}/\text{WavePeak}(T_{\max})$; e *under-peak*, que é avaliado medindo-se o sinal de interferência $X(T_{\max})$ no mesmo instante em que o sinal pulsado atinge sua amplitude máxima, e então calculando-se a razão $X(T_{\max})/\text{WavePeak}(T_{\max})$, conforme Figura 3 [15].

A presença de *crosstalk* nos calorímetros do ATLAS ocorre nas três formas: capacitivo, resistivo e indutivo. Seu efeito compromete a reconstrução precisa das energias depositadas e afeta diretamente a qualidade dos dados experimentais. Por isso, a importância em tratar de sua mitigação para a calibração e interpretação correta dos eventos físicos.

IV. SIMULADOR LORENZETTI SHOWERS

Simuladores de eventos são utilizados na física de altas energias para modelar interações entre partículas e a resposta dos detectores. Eles permitem a análise de efeitos indesejados, como ruído eletrônico e interferências, além de possibilitar a validação de algoritmos de reconstrução antes da aplicação em dados experimentais [16].

O *Lorenzetti Showers Framework* é um simulador de código aberto desenvolvido para experimentos com calorímetros segmentados [4]. Ele permite configurar diferentes geometrias de detectores, tipos de partículas, formas de pulso e condições de operação, incluindo a simulação de efeitos como *pile-up* e *crosstalk*. O processo de simulação no *Lorenzetti* é dividido em quatro etapas: geração de eventos, propagação das partículas, digitalização dos sinais e reconstrução. As bibliotecas *Pythia 8* e *Geant4* são utilizadas para a geração e propagação dos eventos [5].

A Figura 4 ilustra o fluxo de simulação realizado pelo *Lorenzetti Showers Framework*, dividido em quatro etapas principais. Na fase de geração de eventos, o *Pythia 8* é utilizado para simular colisões e produzir partículas estáveis. Em seguida, o *Geant4* realiza a propagação dessas partículas pelo detector simulado, registrando os depósitos de energia e efeitos como *pile-up* e *crosstalk*. Na etapa de digitalização, os sinais




Figura 4. Fluxo de operações no Lorenzetti Showers Framework. Fonte: [4]

analógicos são convertidos em dados digitais, considerando diferentes configurações de leitura e eletrônica. Por fim, na fase de reconstrução, são aplicados algoritmos para extração de variáveis de alto nível que caracterizam os eventos simulados.

A. Dados utilizados

Neste trabalho, foram utilizados dados obtidos do simulador *Lorenzetti*, representando sinais calorimétricos de partículas do tipo elétron. Os dados incluem tanto os sinais verdadeiros quanto versões corrompidas por ruído eletrônico e diferentes componentes de *crosstalk* (capacitivo, indutivo e resistivo), sendo utilizados para o treinamento, validação e teste dos modelos de aprendizado de máquina com o objetivo de estimar a energia verdadeira a partir desses sinais distorcidos.

As informações estão organizadas em *clusters* bidimensionais de 7×7 células, com estrutura vetorial de dimensão (99755, 49), onde cada entrada representa a amplitude de energia estimada em uma célula. Também foram utilizados dados em múltiplas escalas de energia, variando de 10 GeV a 200 GeV, o que amplia a diversidade do conjunto e contribui para a robustez do treinamento. Os principais atributos analisados neste estudo foram: E (energia verdadeira), XT-C, XT-L e XT-R (componentes de *crosstalk* capacitivo, indutivo e resistivo, respectivamente) e *Noise* (ruído eletrônico).

A Figura 5 apresenta a distribuição espacial da energia verdadeira e da energia associada ao efeito de *crosstalk* em um mesmo *cluster* 7×7 . Observa-se que o *crosstalk* tende a se concentrar em torno das células com maior energia depositada, o que está em consonância com o comportamento previsto por modelos teóricos de acoplamento parasitário entre canais.

V. MODELOS PROPOSTOS

Duas arquiteturas de máquinas de aprendizado foram testadas para abordar o problema do *crosstalk*: uma rede do tipo *Multilayer Perceptron* (MLP) e uma *Convolutional Neural Network* (CNN). Ambas foram treinadas utilizando os dados simulados pelo *Lorenzetti Showers Framework*, com divisão comum dos conjuntos: 20% para teste e os 80% restantes subdivididos em 70% para treino e 30% para validação.

Na Figura 6 é exibido o diagrama de blocos das principais etapas de processamento dos modelos propostos.




Figura 5. (a) Distribuição espacial da energia verdadeira; (b) distribuição espacial da energia de crosstalk para um cluster 7×7 .

A. Modelo MLP

O modelo MLP foi aplicado diretamente sobre vetores de entrada normalizados. As principais configurações adotadas foram:

- Camada *Flatten* para preparação dos dados de entrada;
- De 1 a 3 camadas densas com número de neurônios variando de 90 a 490, função de ativação ReLU e regularização L2, com parâmetro de penalização λ variando de 0,001 a 0,01;
- Camada de saída com 49 neurônios, sem função de ativação, para modelar a relação linear final;




Figura 6. Diagrama de blocos das principais etapas de processamento dos modelos treinados

- Otimizador: Adam (com parâmetros: $\alpha = 0,001$, $\beta_1 = 0,9$, $\beta_2 = 0,999$); função de perda: Erro Quadrático Médio (MSE);
- Número máximo de épocas: 100 com *Callbacks EarlyStopping* com paciência de 5 épocas;
- Tamanhos de *batch*: 32 a 256;
- Validação cruzada com 5 *folds*.

B. Modelo CNN

O modelo CNN foi utilizado para explorar a estrutura espacial dos *clusters* de energia, representando os dados como matrizes 7×7 com 1 canal (formato $(7, 7, 1)$). As configurações testadas foram:

- Camada convolucional de entrada (*Conv2D*) com o número de filtros variando entre 9 e 36, em janelas de 2×2 ou 3×3 ; *padding=same*; ativação ReLU e regularização L2, com parâmetro de penalização λ variando de 0,001 a 0,01;
- Uma ou duas camadas convolucionais intermediárias com filtros semelhantes à camada de entrada; opcionalmente seguidas por *MaxPooling2D* (*pool_size = (2, 2)*);
- Camada *Flatten* para conversão dos mapas de ativação;
- De 1 a 2 camadas densas com número de neurônios variando de 90 a 490; ativação ReLU; regularização L2 ($\lambda \in [0,001, 0,01]$) e camadas *Dropout* com probabilidade entre 0,01 e 0,1;
- Camada de saída com 49 neurônios lineares;

- Otimizador: Adam (com parâmetros: $\alpha = 0,001$, $\beta_1 = 0,9$, $\beta_2 = 0,999$); função de perda: Erro Quadrático Médio (MSE);
- *Callbacks* para parada antecipada e salvamento de pesos;
- Número máximo de épocas: 100 com *EarlyStopping* com paciência de 5 épocas;
- Tamanhos de *batch*: 32 a 256;
- Validação cruzada com 5 *folds*.

Todos os experimentos foram conduzidos em ambiente *Python*, utilizando-se principalmente as bibliotecas *TensorFlow/Keras* e *Scikit-learn*. O treinamento dos modelos foi realizado em um computador com processador AMD Ryzen 7 4800H (8 núcleos, 16 *threads*), GPU GeForce GTX 1650 Ti (4 GB VRAM), 24 GB de memória RAM e sistema operacional *Windows* (versão 23H2).

VI. RESULTADOS

Tanto as arquiteturas com MLP quanto com CNN apresentaram resultados interessantes para o tratamento dos sinais. Os modelos MLP, apesar de apresentarem uma performance menor nas previsões em relação aos CNN, tem em compensação um tempo de treinamento consideravelmente menor.

A. Modelo MLP

Foram realizados experimentos com arquitetura MLP com variações em números de neurônios e camadas, além de outros hiperparâmetros. Os resultados em relação as esses primeiros são expostos na Tabela I. Percebe-se que o modelo MLP com melhores resultados contém apenas uma camada oculta e que o aumento da complexidade da arquitetura não implica em melhores resultados.

Tabela I
DESEMPENHO DOS MODELOS MLP COM DIFERENTES ARQUITETURAS

Parâmetro	49-490-49	49-490-196-49	49-490-294-147-49
train_mse	0,1649	0,2000	0,2265
val_mse	0,1653	0,2016	0,2272
test_mse	0,1655	0,2020	0,2277
test R ²	0,8345	0,7982	0,7738

B. Modelo CNN

Nas arquiteturas com redes convolucionais, muito mais combinações surgiram devido às possibilidades de se alterar parâmetros tanto nas camadas convolucionais como na adição de camadas densas junto ao modelo.

No geral, muitas soluções com CNN são possíveis, usando uma ou duas camadas convolucionais com algumas variações de filtros e adicionando-se uma ou duas camadas densas ocultas após as convolucionais. Isto sugere que de fato a topologia dos *clusters* em formatos 7x7 seja bem interpretada pelos modelos com CNN. Versões com redução de dimensionalidade de janelas como com o uso de *MaxPooling*, por exemplo, mostraram-se pouco eficazes e tiveram desempenho significativamente inferior.

Na Tabela II são mostrados os resultados para dois bons modelos com CNN e que apresentam arquiteturas diferentes

juntamente com um modelo com uso de *MaxPooling*, com menor desempenho em relação aos dois primeiros.

Tabela II
DESEMPENHO DOS MODELOS CNN COM DIFERENTES ARQUITETURAS

Parâmetro	C2D 16_3x3 C2D 16_3x3 - 49	C2D 16_3x3 490 - 49	C2D 16_3x3 - MaxPooling (2,2) C2D 16_3x3 - 49
train_mse	0,1481	0,1573	0,3399
val_mse	0,1490	0,1598	0,3307
test_mse	0,1493	0,1600	0,3311
test R ²	0,8507	0,8400	0,6690

C. Comparações e discussões

Na Tabela III vemos a comparação direta entre os melhores modelos encontrados para as arquiteturas MLP e CNN. Percebe-se que no modelo CNN a performance é ligeiramente superior.

Tabela III
COMPARAÇÃO ENTRE DESEMPENHOS DOS MELHORES MODELOS MLP E CNN

Parâmetro	49-490-49 (MLP)	C2D 16_3x3 - C2D 16_3x3 - 49 (CNN)
train_loss	0,1866	0,1503
val_loss	0,1870	0,1512
train_mse	0,1649	0,1481
val_mse	0,1653	0,1490
test_mse	0,1655	0,1493
test R ²	0,8345	0,8507

Também é possível verificar leve superioridade do melhor modelo CNN ao compararmos os gráficos de energia verdadeira x energias preditas, exibidos lado a lado na Figura 7, na qual se verifica que a dispersão no modelo CNN é menor que no MLP.

A partir das comparações apresentadas, percebe-se que a estrutura espacial do cluster 7x7 é bem aproveitada pelas CNNs, que identificam padrões característicos do *crosstalk* e com isso conseguem fornecer previsões melhores. Embora os MLPs sejam mais leves computacionalmente, essas nuances dadas pela geometria dos detectores não foi capturada, trazendo dificuldades maiores para previsões dos modelos apenas com camadas densas.

Para se verificar um exemplo prático do resultado do melhor modelo CNN obtido, aplicado a um cluster, o gráfico da Figura 8 exibe os valores tanto da energia com *crosstalk* e ruído, como a energia verdadeira e predita. Pode-se perceber que o modelo se ajusta bem às células centrais do cluster, com mais energia, que são de fato a região de maior interesse para se mitigar o *crosstalk*.

Em células nas bordas dos clusters, números finais e iniciais nos gráficos, por exemplo, os valores de previsão destoam mais significativamente. Nestas células a influência de ruído se torna mais forte, já que captam pouco os sinais do fenômeno físico em si e, portanto, uma proporção maior de contaminação ruidosa.




Figura 7. (a) Relação entre energia verdadeira e predita pelo modelo MLP; (b) relação entre energia verdadeira e predita pelo modelo CNN; (c) relação entre energia verdadeira e energia contaminada com crosstalk.




Figura 8. Energias contaminada, verdadeira e predita por modelo CNN para um *cluster* 7x7.

Além disso, a visão por *heatmap* das comparações entre as energias contaminadas, verdadeira e prevista podem ser vistas na Figura 9, na qual se nota o nível de semelhança entre as energias verdadeira e predita no cluster, com menor disparidade nas células centrais em relação ao cluster com energia contaminada. E de uma outra maneira mais direta para visualizar a diferença ao se aplicar o melhor modelo CNN obtido, o gráfico comparativo da Figura 10 apresenta as diferenças entre as energias contaminada e verdadeira e entre a predita e a verdadeira, também em *heatmap*, donde se nota a eliminação do padrão do *crosstalk*.

VII. CONCLUSÃO

Com base nos dados gerados pelo *Lorenzetti Showers Framework*, foi possível desenvolver modelos de aprendizado de máquina utilizando MLPs e CNNs com o objetivo de mitigar os efeitos de *crosstalk* em sinais calorimétricos simulados. Ambos os modelos demonstraram eficácia na reconstrução da energia verdadeira das partículas, mesmo diante da presença de ruído eletrônico e interferência.

O desempenho superior das redes convolucionais ficou evidente nas métricas quantitativas, bem como nas visualizações espaciais que demonstraram maior aderência aos padrões reais de distribuição da energia. A CNN apresentou melhor capacidade de generalização ao identificar as regiões mais afetadas pela interferência, especialmente ao redor das células com maior energia depositada — ponto de interesse central na física de altas energias.

Os resultados obtidos indicam que modelos baseados em convolução são promissores para tarefas de limpeza e reconstrução de sinais em calorímetros segmentados. Como desdobramento futuro, pretende-se avaliar a aplicabilidade do modelo em dados experimentais reais.

VIII. AGRADECIMENTOS

Os autores agradecem ao CNPq e à CAPES (Programa CAPES-COFECUB) pelo apoio financeiro e ao Grupo de Processamento de Áudio Digital (GPAD) da Universidade Federal da Bahia pelas valiosas contribuições intelectuais e sugestões.




Figura 9. (a) Energia contaminada; (b) energia verdadeira; (c) energia predita pelo modelo CNN para um cluster 7×7 .




Figura 10. (a) Diferença absoluta entre energia contaminada e verdadeira; (b) diferença absoluta entre energia predita pelo modelo CNN e verdadeira.

REFERÊNCIAS

- [1] L. Evans, The Large Hadron Collider: A Marvel of Technology, 2nd ed. Lausanne: EPFL Press, 2019.
- [2] M. J. Shroff, Development of the ATLAS Liquid Argon Calorimeter Readout Electronics for the HL-LHC, Hamburg, Germany, Oct. 2023.
- [3] J. V. F. Pinto, J. Lieberman, W. Freund, G. G. Milan, M. V. Araújo, and G. Gonçalves, *lorenzetti-hep/lorenzetti: 2.0.0 (2.0.0)*. Zenodo, 2022. Disponível em: <https://doi.org/10.5281/zenodo.7494463>. DOI: 10.5281/zenodo.7494463. Acesso em: 27 jan. 2025.
- [4] M. V. Araújo, M. Begalli, W. S. Freund, G. I. Gonçalves, M. Khandoga, B. Laforge, A. Leopold, J. L. Marin, B. S.-M. Peralva, J. V. F. Pinto, M. S. Santos, J. M. Seixas, E. F. Simas Filho, E. E. P. Souza, *Lorenzetti Showers: A general-purpose framework for supporting signal reconstruction and triggering with calorimeters*, Brazil, Jan. 2023.
- [5] J. V. da Fonseca Pinto, J. Lieberman, W. Freund, G. G. Milan, M. V. de Araújo, and G. Gonçalves, *lorenzetti: A Framework for HEP Data Analysis, Version 2.0.0*, Dec. 2022. [Online]. Available: <https://github.com/lorenzetti-hep/lorenzetti>

- [6] M. S. dos Santos, P. C. M. A. Farias, E. F. de Simas Filho, B. Laforge, J. M. de Seixas, *Redes Neurais como um método de redução do Crosstalk entre sensores no calorímetro eletromagnético do experimento ATLAS*, Salvador, Brazil; Paris, France; Rio de Janeiro, Brazil, s.d.
- [7] M. S. dos Santos, *Computational Intelligence Methods Applied for Crosstalk Reduction in ATLAS Liquid Argon Calorimeter*, Ph.D. thesis, Department of Electrical and Computer Engineering, Federal University of Bahia (UFBA), Salvador, Brazil, 2023. Supervisors: Paulo C. M. A. Farias; Eduardo F. de Simas Filho; Bertrand Laforge.
- [8] M. Beech, *The Large Hadron Collider: Unraveling the Mysteries of the Universe*. Berlin: Springer, 2010.
- [9] A. A. Abdelalim, *Study on the Impact of Crosstalk in the ATLAS Electromagnetic Calorimeter on the Signal Prediction in the Strip Layer*. Tese (Doutorado) – Département de Physique Nucléaire et Corpusculaire, Université de Genève, Genebra, setembro 2008.
- [10] M. N. Agaras, A. Ahmad, A. Blanco, D. Boumediene, R. Bonnefoy, D. Calvet, M. Calvetti, *et al.*, *Laser calibration of the ATLAS Tile Calorimeter during LHC Run 2*. Journal of Instrumentation, vol. 18, no. 06, p. P06023, jun. 2023. Disponível em: <https://dx.doi.org/10.1088/1748-0221/18/06/P06023>. DOI: 10.1088/1748-0221/18/06/P06023. Acesso em: 27 jan. 2025.
- [11] ATLAS Collaboration. *Improving topological cluster reconstruction using calorimeter cell timing in ATLAS*. CERN, 1211 Geneva 23, Switzerland.
- [12] ATLAS, *Liquid Argon Calorimeter: Technical Design Report*. CERN, 2006.
- [13] S. Baffioni, *et al.*, *Electrical measurements on the ATLAS electromagnetic barrel calorimeter*. ATLAS Internal Note, ATL-LARG-PUB-2007-005, 2007.
- [14] G. Aad, *et al.*, *Topological cell clustering in the ATLAS calorimeters and its performance in LHC Run 1*. European Physical Journal C, 2017. Disponível em: <https://doi.org/10.1140/epjc/s10052-017-5004-5>. arXiv:1603.02934v3 [hep-ex]. Acesso em: 27 jan. 2025.
- [15] M. Stricker, *Crosstalk measurement in the ATLAS electromagnetic calorimeter using muons*. Dissertação (Mestrado em Física) – Physikalisches Institut, Mathematisch-Naturwissenschaftlichen Fakultät, Rheinischen Friedrich-Wilhelms-Universität Bonn, junho 2023.
- [16] T. Plehn, A. Butter, B. Dillon, T. Heimel, C. Krause, R. Winterhalder, *Modern Machine Learning for LHC Physicists*. Tese (Doutorado) – Institut für Theoretische Physik, Universität Heidelberg, Heidelberg, Alemanha, 2024.