

Modelos Lineares Assistidos por Redes Neurais para Estimação Online da Energia do Calorímetro de Telhas do ATLAS

G. I. Gonçalves, G. B. Libotte, B. S. Peralva

Departamento de Modelagem Computacional

Instituto Politécnico, Universidade do Estado do Rio de Janeiro

Nova Friburgo, Brasil

inacio.guilherme@gmail.com, gustavolibotte@iprj.uerj.br, bernardo@iprj.uerj.br

L. M. de Andrade Filho

Universidade Federal de Juiz de Fora

Juiz de Fora, Brasil

luciano.andrade@ufjf.edu.br

L. E. Balabram Filho, J. M. de Seixas

Laboratório de Processamento de Sinais

Universidade Federal do Rio de Janeiro

Rio de Janeiro, Brasil

balabramfilho@gmail.com, seixas@lps.ufrj.br

Resumo—O experimento ATLAS no LHC está passando por uma atualização significativa, dividida em duas fases, para lidar com a alta luminosidade do LHC. Na Fase-II, prevista para entrar em operação em 2029, haverá uma evolução da arquitetura eletrônica de leitura, permitindo a realocação dos componentes eletrônicos visando a implementação do modo *free-running* de processamento digital de sinais. Durante esta fase de operação, espera-se um aumento substancial no número de interações de partículas por colisão, o que pode apresentar desafios para os algoritmos de processamento de sinais, especialmente para os calorímetros onde as flutuações causadas pelo efeito de empilhamento de sinal degradam a resolução de energia. O método do Filtro Ótimo, utilizado atualmente no calorímetro de telhas do ATLAS, busca minimizar a variância do ruído eletrônico, mas pode resultar em erros sistemáticos quando os pulsos se sobrepõem, levando a uma estimativa imprecisa da amplitude do sinal em cenários de alta luminosidade e de processamento ininterruptos de sinais. Neste trabalho, avaliamos a alternativa de usar o método de mínimos quadrados, que busca encontrar um estimador que minimize a diferença entre os dados observados e o modelo do sinal, sujeito a restrições lineares. Esta estratégia é conjugada com o emprego de uma rede neural perceptron multicamadas, visando a sua atuação como um corretor não-linear das estimativas da energia estimada pelo método de mínimos quadrados, tornando este significativamente mais preciso.

Palavras-chave—Modelos lineares, redes neurais, empilhamento de sinais, calorimetria de altas energias.

I. INTRODUÇÃO

Durante os últimos anos, o processamento digital de sinal se aproximou cada vez mais das soluções de hardware analógico. Empresas e experimentos científicos buscam extrair

de forma eficiente dos enormes conjuntos de dados ilimitados que permeiam nosso mundo. Neste contexto, técnicas baseadas em inteligência computacional agregadas à sistemas de processamento de dados ininterruptos, também conhecido como processamento *streaming* ou *free-running* finalmente atingiram um nível de maturidade suficiente para a adoção convencional [1], inclusive em experimentos modernos de física de altas energias [2], [3].

Neste trabalho, exploramos o sistema de calorimetria do experimento ATLAS no acelerador de partículas Large Hadron Collider (LHC), localizado no complexo do CERN. O LHC é atualmente o maior e mais poderoso acelerador de partículas do mundo, capaz de alcançar colisões com uma energia de centro de massa de 13,6 TeV [4]. Através dessas colisões, uma vasta gama de fenômenos físicos de grande relevância é investigada, como o evento de uma partícula com propriedades consistentes com o bóson de Higgs do modelo padrão, observada pela primeira vez em 2012 [5], [6]. O experimento ATLAS, um dos quatro principais experimentos instalados no LHC, é projetado para analisar colisões próton-próton e investigar as partículas produzidas nesses eventos. Neste estudo, concentramos nossa atenção nos sistemas de calorimetria do ATLAS, em particular no futuro aprimoramento da infraestrutura do seu principal calorímetro hadrônico, ou TileCal, que desempenha um papel crucial na medição da energia das partículas geradas nas colisões que com ele interagem. Esses sistemas absorvem e quantificam a energia das partículas que passam por eles, permitindo a determinação de propriedades essenciais das partículas.

Com base nos planos de atualização da colaboração ATLAS para o LHC de alta luminosidade (HL-LHC), o experimento passará por uma atualização significativa, dividida em duas fases: Fase-I e Fase-II. Essas atualizações são necessárias para lidar com a alta luminosidade do HL-LHC, que resultará em um aumento substancial no número de colisões simultâneas. Durante a Fase-II, a arquitetura eletrônica de leitura será aprimorada para lidar com até 200 interações simultâneas próton-próton a cada colisão [7].

No entanto, a intensificação do efeito de empilhamento de sinal devida a maior ocupação do detector (aumento da luminosidade) apresenta desafios significativos. Especificamente, o efeito de empilhamento de sinal distorce os pulsos de sinal, afetando negativamente a precisão da estimativa de amplitude (energia). Isso resulta em erros sistemáticos na determinação da energia depositada pelas partículas nos calorímetros. Portanto, este estudo se concentra nas estratégias de reconstrução de energia para mitigar os efeitos do empilhamento de sinal nos calorímetros, visando melhorar a precisão das medições [8].

Atualmente, o método do Filtro Ótimo (OF) [9] é amplamente utilizado na reconstrução de energia dos calorímetros do ATLAS. Esse algoritmo busca minimizar a variância do ruído eletrônico presente nos calorímetros, aproveitando o conhecimento da forma do pulso de referência. No entanto, em condições de alta luminosidade e empilhamento de sinal, a forma do pulso real pode se desviar significativamente do pulso de referência, comprometendo a precisão da estimativa de amplitude [10].

Nesse cenário, exploramos o método de mínimos quadrados (LS) como uma abordagem promissora para a reconstrução de energia dos calorímetros do ATLAS. O método de mínimos quadrados é uma técnica bem estabelecida que busca encontrar os parâmetros de um modelo matemático que minimizam a soma dos quadrados das diferenças entre as observações reais e as estimativas do modelo [11]. Ao aplicar o método de mínimos quadrados à reconstrução de energia, buscamos encontrar os valores de amplitude que melhor se ajustam aos pulsos distorcidos pelo empilhamento de sinal, levando em consideração as características conhecidas do pulso de referência e as variações introduzidas pelo empilhamento de sinal.

A adoção do método de mínimos quadrados para a reconstrução de energia dos calorímetros do ATLAS oferece várias vantagens. Primeiro, o método é flexível e pode lidar com variações na forma do pulso causadas pelo empilhamento de sinal. Ao ajustar os parâmetros do modelo matemático aos dados reais, o método de mínimos quadrados é capaz de capturar as variações introduzidas pelo empilhamento de sinal e fornecer estimativas mais precisas da amplitude do sinal. Além disso, o método de mínimos quadrados permite levar em consideração informações adicionais, como as flutuações do ruído eletrônico nos calorímetros, melhorando ainda mais a precisão das estimativas de energia. Por fim, o método fornece rápida velocidade de processamento e fácil implementação sendo, portanto, atrativo para a operação online.

Visando assistir a medida linear estabelecida, e considerando a aplicação online, propomos o uso de uma rede neural artificial perceptron multicamadas (MLP) como forma de corrigir e aprimorar os estimadores obtidos usando o método de mínimos quadrados. A MLP pode ser utilizada como um corretor não-linear dos pesos estimados pelo método de mínimos quadrados. Essa abordagem permitiria ao sistema aprender e modelar a relação entre os pulsos distorcidos e a energia depositada, mesmo em situações de alta luminosidade e empilhamento de sinais. Ao treinar a rede neural com uma quantidade significativa de dados de entrada e saída corretamente associados, é possível capturar padrões complexos e realizar uma correção precisa dos efeitos indesejados nos pulsos. Ao implementar uma rede neural do tipo MLP como corretor não-linear para a reconstrução de energia em calorimetria, espera-se obter resultados mais precisos e confiáveis, mesmo em condições desafiadoras de empilhamento de sinais. Essa abordagem representa uma oportunidade promissora para melhorar o desempenho dos calorímetros do ATLAS e contribuir para o avanço da pesquisa no contexto da atualização da Fase-II do LHC.

Na seção seguinte, o ambiente de trabalho utilizado como base para o estudo feito neste artigo é apresentado. Na Seção III, o problema de estimação da energia em condições de empilhamento de sinais é abordado. Os métodos utilizados para a reconstrução dos sinais do TileCal são apresentados na Seção IV. A Seção V apresenta a análise de eficiência empregada para avaliar o desempenho dos métodos considerados. Finalmente, a Seção VI aborda as discussões finais sobre o trabalho e perspectivas futuras.

II. INFRAESTRUTURA ATUAL E ATUALIZAÇÃO ESPERADA DO TILECAL

O experimento ATLAS no LHC foi projetado para medir colisões próton-próton em energias multi-TeV. Nessas colisões, feixes contendo até 10^{11} prótons colidem com uma frequência de 40 milhões de vezes por segundo, resultando em colisões próton-próton com uma energia de centro de massa de 14 TeV e uma luminosidade projetada de $10^{34} \text{ cm}^{-2} \text{ s}^{-1}$ [12], que é a razão entre o número de eventos por segundo e a área do feixe de partículas. Mais especificamente, os calorímetros hadrônicos são responsáveis por medir a energia dos hádrons conforme eles interagem com os núcleos atômicos. No TileCal, quando um hádron percorre o interior do calorímetro, inicia-se uma cascata de partículas, havendo perda de energia ao passar pelo material passivo (aço) e interagir com o material ativo (telhas cintilantes), resultando na emissão de luz. Essa luz é transmitida por várias fibras ópticas, que formam coletivamente o sinal da célula. Essas fibras são agrupadas e posteriormente direcionadas para um fotomultiplicador, que produz um pulso elétrico em resposta ao sinal de luz. O processo de coleta do sinal do TileCal é mostrado na Fig. 1.

Para padronizar o pulso, um circuito modelador (*shaper*) o condiciona, garantindo uma forma conhecida e uma amplitude proporcional à energia depositada. Este pulso analógico é então convertido para o formato digital por um Conversor

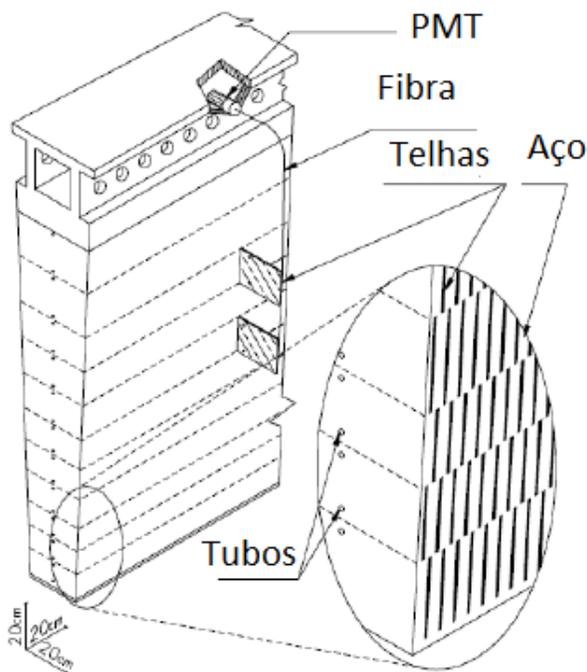


Figura 1: Estratégia adotada no TileCal do ATLAS para coleta dos sinais absorvidos.

Analogico-Digital (ADC) operando a uma frequência de amostragem de 40 MHz. O ADC captura o pulso dentro de uma janela de 150 ns compreendendo 7 amostras digitais, cobrindo todo o pulso [13].

Hristova [7] apresenta um resumo dos planos da colaboração ATLAS para o LHC de alta luminosidade, conhecido como HL-LHC. O detector ATLAS está programado para passar por uma atualização significativa, que será realizada em duas fases distintas, denominadas Fase-I e Fase-II. Essas fases serão sincronizadas com a programação do HL-LHC. A atualização do próprio LHC será implementada gradualmente, começando em 2019–2020 com a Fase-I e culminando no comissionamento da configuração final da máquina HL-LHC durante 2023–2025 com a Fase-II.

Como os feixes de prótons colidem a uma frequência de 40 MHz, isso corresponde a colisões que ocorrem a cada 25 ns. Na Fase-II, é necessária uma evolução da arquitetura eletrônica de leitura, onde os dados serão transmitidos para fora do detector, resultando em uma redução da complexidade e da eletrônica no detector. Isso é possível pela utilização de *links* e receptores ópticos de alta qualidade e alta velocidade, que permitem a realocação desses componentes para longe do detector, visando o chamado esquema *free-running* (ininterrupto) [7] de modo que os algoritmos que operam de forma online deverão computar a energia para todo evento. Nesta configuração, a eletrônica de leitura do TileCal será substituída e toda a informação será transmitida de forma digital para o sistema de filtragem (*Trigger*) do ATLAS [14].

Durante a fase de alta luminosidade do LHC, a máquina é projetada para atingir luminosidades instantâneas variando

de 5 para $7 \times 10^{34} \text{ cm}^{-2} \text{ s}^{-1}$ [15]. Em outras palavras, o número de colisões por cruzamento de feixe (μ), é projetado para chegar a 200 no último modo operacional do HL-LHC. Isso representa um aumento substancial em comparação com o projeto do LHC e os valores de μ atualmente alcançados de aproximadamente 75 [7]. A maior ocupação do detector pode, no entanto, apresentar desafios. Particularmente em calorímetros, as flutuações causadas pelo *pile-up* em alta luminosidade podem degradar a resolução de energia [12]. Abaixo, fornecemos mais detalhes sobre o efeito de empilhamento de sinal (*signal pile-up*).

III. O EFEITO DE EMPILHAMENTO DE SINAL

A forma de pulso do TileCal se estende além do espaçamento do feixe do LHC, resultando em um intervalo de tempo mais amplo. Conseqüentemente, em canais com alta ocupação, ocorrem colisões consecutivas dentro da mesma janela de leitura. Dado que a altura do pulso e o tempo do pico são informações pertinentes, idealmente, uma única amostra no momento em que o sinal atinge seu máximo deve ser suficiente. Porém, na prática, variações no tempo introduzem maiores imprecisões nas medições de energia e, conseqüentemente, afetam a amplitude proporcional do pulso. Além disso, devido ao tempo de desvio estendido, múltiplos pulsos de cruzamentos de feixes consecutivos podem se sobrepor. As colisões próton-próton simultâneas que ocorrem no mesmo cruzamento de grupo intensificam o problema, resultando no que é conhecido como empilhamento de sinal no tempo. Este fenômeno distorce o sinal desejado e impacta negativamente a precisão do desempenho da estimativa de amplitude [16], [17]. A Figura 2 ilustra o efeito de empilhamento de sinal.

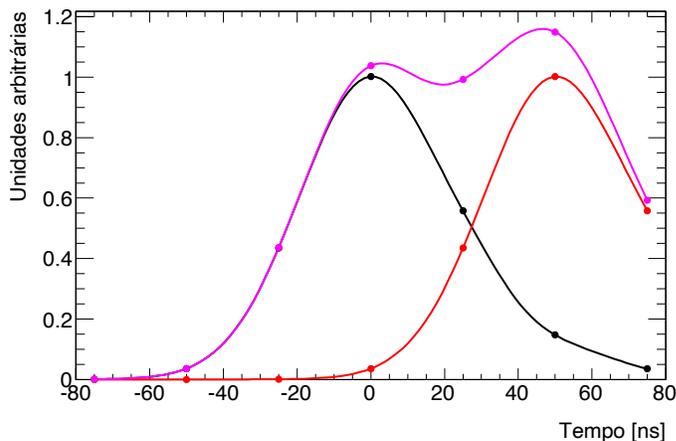


Figura 2: Efeito do empilhamento de sinal. Antes que um novo pulso seja gerado, observa-se um sinal de interesse (preto), porém, nesse momento, também é identificado um sinal (vermelho) proveniente de uma colisão adjacente, resultando na distorção do sinal combinado (magenta).

Como parte da atualização da Fase-II do LHC, a eletrônica de leitura dos calorímetros ATLAS está sendo aprimorada para acomodar operações de alta luminosidade, antecipando

um empilhamento de até 200 interações simultâneas próton-próton. Além disso, os sinais dos calorímetros são afetados pela sobreposição de até 25 colisões consecutivas, complicando ainda mais a tarefa de reconstrução de energia [18]. À medida que a luminosidade aumenta, o número de colisões geradas também aumenta devido às interações intensificadas entre os prótons durante a interseção do feixe. Isso pode ser atribuído ao diâmetro maior do feixe de prótons. Embora essa maior luminosidade aumente a probabilidade de detecção de eventos físicos desejados, ela também aumenta as chances de ocorrência de eventos dentro do mesmo canal de leitura do sistema de calorimetria ATLAS. Como resultado, o efeito de empilhamento de sinais torna-se mais pronunciado [17].

Em tais condições, o desempenho dos filtros digitais clássicos diminui à medida que a forma do pulso do sinal se torna distorcida.

IV. ESTRATÉGIAS DE RECONSTRUÇÃO DE ENERGIA

Em calorímetros convencionais, os sinais gerados dentro do detector passam por condicionamento, modelagem e digitalização na parte eletrônica frontal antes de serem transmitidos para a parte traseira para reconstrução do sinal. Posteriormente, filtros digitais são empregados para determinar a amplitude real do pulso analógico, que é diretamente proporcional à energia depositada no detector.

A. Considerações preliminares

Considere uma sequência de sinais digitais s em que no instante j , desconsiderando-se o efeito de desvios de fase ou deslocamentos de linha de base, cada amostra pode ser representado por $s^{(j)} = Ag^{(j)} + \sigma^{(j)}$, onde A representa a amplitude do sinal recebido, $g^{(j)}$ é uma amostra do pulso de referência e $\sigma^{(j)}$ é um ruído aditivo, para $j = 1, \dots, M$, tal que M é o número de eventos observados. Neste caso, consideramos pulsos de referência periódicos, cobrindo todos os instantes de tempo M . Ainda, assumamos que existe uma matriz \mathbf{H} , com dimensão $N \times p$. Para uma quantidade arbitrária p de observações contíguas do sinal, podemos rearranjar o conjuntos de amostras tomando $N = M/p$, de forma a criar “janelas” com tamanho p de dados sequenciais. Cada uma dessas janelas de dados podem, portanto, compor as linhas da matriz \mathbf{H} . Note que o cálculo da quantidade N pode levar a $M = Np + d$, com o inteiro $d > 0$. As amostras d podem ser descartadas sem prejuízos já que, em geral, $M \gg d$.

Na área da física de altas energias, a energia do sinal de interesse é avaliada por meio da estimativa da amplitude do pulso captado pelo sistema de calorimetria. Neste contexto, considere que temos disponível um conjunto de M valores de amplitude $\mathbf{X} = (X_1, \dots, X_j, \dots, X_M)^T$ associadas aos eventos observados. Podemos tomar as amplitudes $\mathbf{x} = (x_1, \dots, x_i, \dots, x_N)^T$ correspondentes aos valores centrais de cada janela de \mathbf{X} se a matriz for convenientemente reorganizada como uma matriz $N \times p$, seguindo procedimento análogo ao adotado para compor \mathbf{H} . Assim, podemos afirmar que um sinal $\mathbf{a} = (a_1, \dots, a_i, \dots, a_N)^T$, puramente

determinístico, depende de um parâmetro desconhecido $\boldsymbol{\theta} = (\theta_1, \dots, \theta_k, \dots, \theta_p)^T$ para que a relação $\mathbf{a} = \mathbf{H}\boldsymbol{\theta}$ seja válida.

B. Metodologia atual: o método do Filtro Ótimo

O método do Filtro Ótimo (OF) [19] é um algoritmo amplamente utilizado em calorímetros modernos, como o do experimento ATLAS. Ele busca minimizar a variância do ruído eletrônico presente nos calorímetros, utilizando o conhecimento da forma do pulso de referência. O sinal de entrada é modelado como a soma do pulso de referência, o ruído, a fase do sinal e o pedestal. O método OF estima a amplitude do sinal de entrada em condições de baixa luminosidade, através de uma soma ponderada dos valores amostrados do sinal. Os coeficientes do filtro OF são calculados aproximando o sinal digital recebido pela sua série de Taylor de primeira ordem e garantindo que o estimador seja imparcial, ou seja, tenha um valor esperado igual à amplitude real do sinal. Além disso, restrições são impostas aos coeficientes para garantir a imparcialidade do estimador em relação ao pedestal e à fase. No que tange a inclusão de restrições, duas versões do estimador OF são utilizadas neste trabalho: OF 1 quando a restrição de imparcialidade em relação ao pedestal não é utilizada, mantendo somente a imparcialidade em relação à fase, e a versão OF 2, quando ambas as restrições são utilizadas no procedimento de otimização. Vale ressaltar que, atualmente, o o TileCal utiliza a versão OF 2 como método de estimação de energia.

A variância do estimador é calculada utilizando a matriz de covariância do ruído, e os pesos do filtro são determinados minimizando essa variância através do método dos multiplicadores de Lagrange. A solução do sistema resulta nos pesos do estimador OF, que são utilizados para operações online e offline no TileCal.

O filtro OF é baseado na modelagem do pulso de referência conhecido, mas quando os pulsos se sobrepõem, a forma do pulso real pode se desviar significativamente do pulso de referência, comprometendo a precisão da estimativa. Em sistemas de alta luminosidade, o empilhamento de sinal pode resultar em pulsos com características diferentes das esperadas. Isso pode levar a erros sistemáticos na estimativa da amplitude do sinal, uma vez que a modelagem do pulso pode não capturar adequadamente essas variações.

C. Método de mínimos quadrados

Visando minimizar o desvio entre \mathbf{x} e \mathbf{a} , um estimador de mínimos quadrados $\hat{\boldsymbol{\theta}}$ pode ser obtido minimizando-se a soma do quadrado dos erros $\mathbf{e} = \mathbf{x} - \mathbf{a}$, o que é equivalente a minimizar $(\mathbf{x} - \mathbf{H}\boldsymbol{\theta})^T (\mathbf{x} - \mathbf{H}\boldsymbol{\theta})$. O número N de observações tende a ser maior que o número p de incógnitas, então deve-se esperar que $\mathbf{H}\boldsymbol{\theta} = \mathbf{x}$ seja inconsistente. Provavelmente, não existirá uma escolha de $\boldsymbol{\theta}$ que se ajuste perfeitamente aos dados de amplitude \mathbf{x} . Ou seja, o vetor \mathbf{x} provavelmente não será uma combinação das colunas de \mathbf{H} . Apesar disso, não foi feita nenhuma suposição probabilística em relação aos dados \mathbf{x} , o que significa que o método é válido tanto para ruído Gaussiano quanto não Gaussiano.

Obter um estimador de mínimos quadrados $\hat{\theta}$ que minimize e , é o mesmo que localizar um ponto $\mathbf{H}\hat{\theta}$ que esteja o mais próximo possível de \mathbf{x} do que qualquer outro ponto no espaço coluna. Portanto, o vetor de erro e deve ser perpendicular a cada coluna $\mathbf{h}_1, \dots, \mathbf{h}_p$ de \mathbf{H} , o que é equivalente a tomar $\mathbf{h}_k^\top (\mathbf{x} - \mathbf{H}\hat{\theta}) = 0$, para $k = 1, \dots, p$. Assumindo a hipótese de que a matriz \mathbf{H} possui posto completo p , computar um estimador de mínimos quadrados $\hat{\theta}$ significa portanto calcular

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

onde a igualdade $\mathbf{H}^\top \mathbf{H}\hat{\theta} = \mathbf{H}^\top \mathbf{x}$ é conhecida como *equação normal* e $\mathbf{H}^\top \mathbf{H}$ é invertível quando as colunas de \mathbf{H} são linearmente independentes. Para a descrição e derivação detalhada do método, consulte a Ref. [20].

D. Rede Neural Perceptron Multicamadas

No projeto em questão, a rede neural perceptron multicamadas (MLP, do inglês *Multi-Layer Perceptron*) pode ser utilizada como um corretor não-linear dos pesos estimados pelo método de mínimos quadrados. A MLP atua como uma função de mapeamento não-linear que busca ajustar os pesos estimados de forma a melhorar a precisão das estimativas.

A MLP consiste em uma arquitetura de rede neural artificial com múltiplas camadas, incluindo camadas de entrada, camadas escondidas e uma camada de saída. Cada camada é composta por um conjunto de neurônios interconectados, onde cada neurônio recebe entradas ponderadas, aplica uma função de ativação e produz uma saída. Nesta aplicação em particular, a abordagem utilizada consiste em treinar a MLP para aprender uma função não-linear que mapeie as amplitudes observadas \mathbf{x} para as amplitudes previstas \mathbf{a} . Levando em conta que cada um dos conjuntos de treinamento e de teste possui M amostras, adotamos a proporção de 70% e 30% no primeiro conjunto para treinamento e validação da MLP, respectivamente, ao passo que o conjunto de teste foi integralmente usado para a tarefa correspondente. A MLP possui duas camadas escondidas com oito neurônios cada, além de uma camada de saída com um neurônio. Cada camada pode incluir um neurônio *bias* para permitir deslocamentos lineares. A ideia fundamental da estratégia proposta ilustrada a Fig. 3, onde o sinal de entrada \mathbf{s} possui 13 amostras temporais.

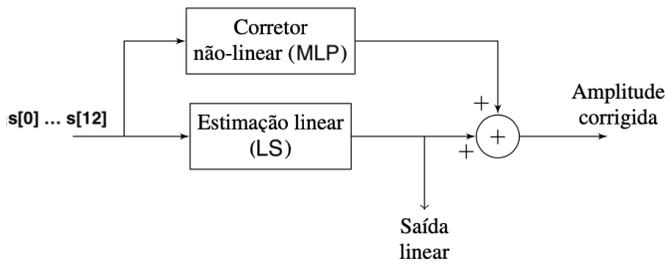


Figura 3: Estratégia proposta para corrigir não-linearidades introduzidas pelo empilhamento no cenário de atualização do TileCal.

A função de ativação escolhida para os neurônios da camada escondida é a sigmóide, enquanto a função de ativação para o neurônio da camada de saída é linear. A função de perda utilizada é o MSE (*Mean Squared Error*), que mede a diferença quadrática média entre as amplitudes previstas e observadas. Por sua vez, o algoritmo otimizador selecionado é o de Levenberg-Marquardt [21], [22], que busca minimizar a função de perda ajustando os pesos da MLP de forma iterativa. Esse algoritmo é uma extensão do método de Gauss-Newton e combina os benefícios dos métodos do gradiente descendente e da matriz Hessiana para encontrar uma solução mais eficiente.

V. RESULTADOS E DISCUSSÃO

Inicialmente, estamos interessados em investigar como a escolha da ordem do filtro pode ser preponderante na reconstrução do sinal. Para tanto, consideramos três cenários que diferenciam-se em termos do nível de ocupação do detector. Tomamos níveis de ocupação iguais a 10%, 30% e 50%. Em termos práticos, isso equivale às chances de se produzir um sinal verdadeiro gerado em um dado tempo e que corresponde a uma colisão, isto é, o número médio de interações próton-próton que ocorre a cada colisão, produzindo um sinal efetivo. Para cada nível de ocupação, criamos dois conjuntos de dados, de treinamento e de teste, contendo sinais amostrados por um gerador de pulso capaz de simular eventos cujos dados resultantes são análogos àqueles provenientes de colisões próton-próton no LHC [10]. Cada conjunto contém $M = 7.000.000$ de amostras, geradas a uma taxa de amostragem de 25 ns. Os conjuntos de dados contêm sinais com amplitudes que seguem a distribuição uniforme no intervalo $[0, 1023]$ em contagens de ADC, corrompidos com ruído eletrônico.

Para analisar as implicações da ordem p do filtro, escolhemos arbitrariamente valores inteiros ímpares que variam no intervalo $p \in [7, 19]$. Escolher apenas valores ímpares para a ordem do filtro decorre da necessidade de tomarmos um valor particular de amplitude em cada uma das N janelas. Com essa configuração, o vetor de amplitudes \mathbf{x} é composto por N valores que correspondem aos dados centrais de cada janela. Nestas condições, calculamos o estimador de LS para cada nível de ocupação, adotando as ordens de filtro prescritas, por meio da Eq. (1). A Fig. 4 apresenta a eficiência de reconstrução da energia medida através da dispersão (RMS) do erro de estimação da amplitude dos sinais considerando os filtros LS em diferentes configurações e níveis de ocupação.

Conforme esperado, o erro de estimação aumenta à medida que a ocupação cresce, assim como pode ser visto comparando-se o RMS de cada conjunto de pontos com marcadores distintos. Para a escolha da melhor ordem do filtro LS, foi tomada aquela que apresenta o menor valor diante de uma menor variação na eficiência (menor que 2 contagens de ADC), o que indica estabilidade da eficiência. Neste caso, foi escolhido o filtro LS de ordem 13 para os três cenários de ocupação.

Com os resultados alcançados para cada estimador de mínimos quadrados, a amplitude do sinal de interesse, de-

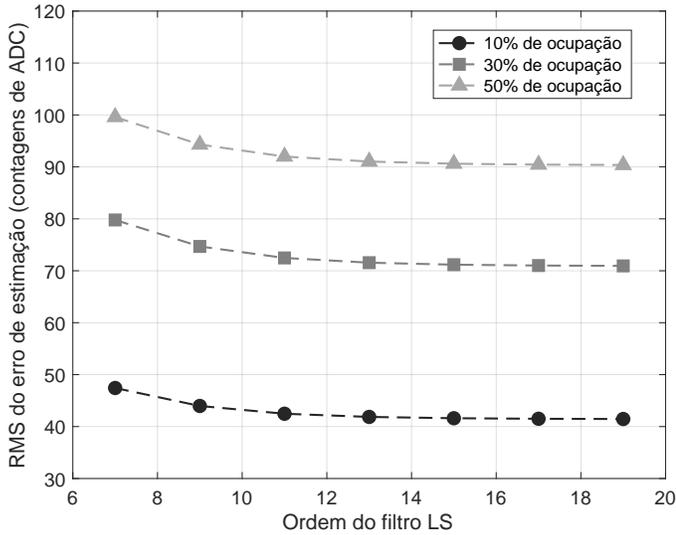


Figura 4: Eficiência de estimação da energia em função da ordem do filtro LS considerando os três cenários de ocupação.

notada como $\hat{\mathbf{A}} = (\hat{A}_1, \dots, \hat{A}_j, \dots, \hat{A}_{M-p+1})^\top$, pode ser reconstruída pela soma ponderada das amostras, isto é,

$$\hat{A}_j = (s_j, \dots, s_{j+p-1}) (\hat{\theta}_1, \dots, \hat{\theta}_p)^\top.$$

Descartando-se $p - 1$ valores de amplitude do conjunto de treinamento, podemos calcular o erro de estimação, representado pelo conjunto $\mathbf{E} = (E_1, \dots, E_j, \dots, E_{M-p+1})^\top$, computando a diferença entre as amplitudes do sinal de interesse e as amplitudes do conjunto de teste nos instantes de tempo correspondentes, visando avaliar a eficiência das estratégias de

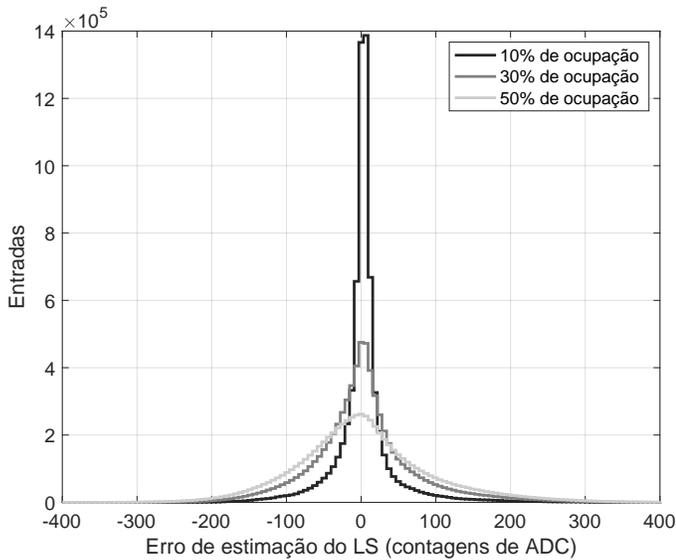
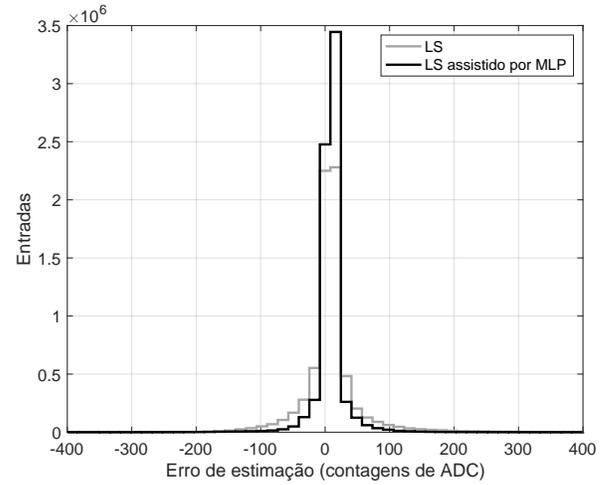
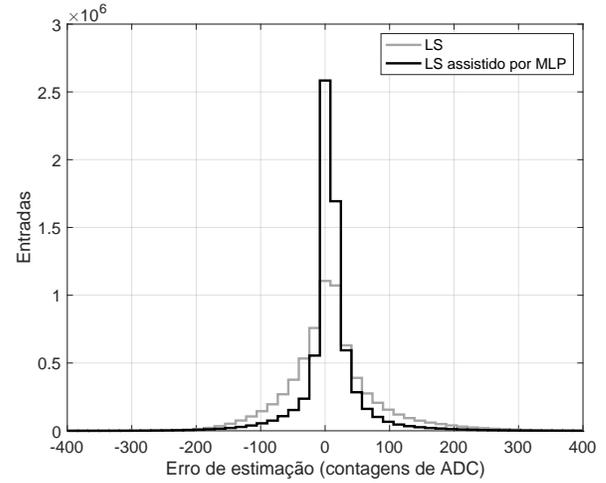


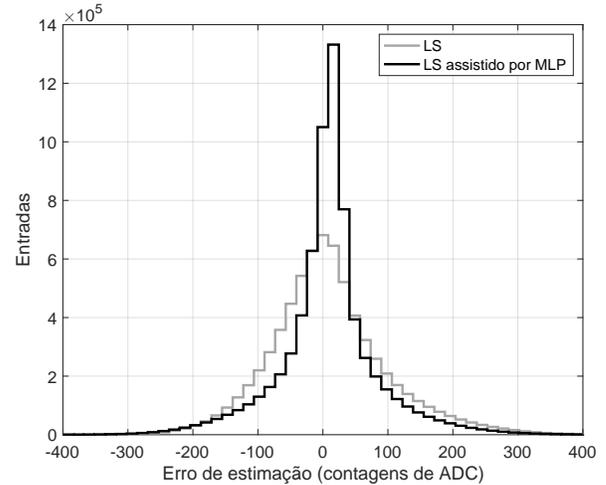
Figura 5: Eficiência de estimação da energia em função da ordem do filtro LS considerando os três cenários de ocupação.



(a)



(b)



(c)

Figura 6: Erros de estimação do método LS com e sem a correção por MLP, representados pelos histogramas em preto e cinza, respectivamente, considerando as ocupações de (a) 10%, (b) 30% e (c) 50%.

estimação de energia para cada configuração, isto é,

$$\left(\mathbf{E}\right)_j = \left(\hat{\mathbf{A}}\right)_j - \left(\mathbf{X}\right)_j, \quad (2)$$

para $j = 1, \dots, M-p+1$. Para cada ordem de filtro analisada, computamos RMS do erro de estimação da amplitude, em contagens de ADC, para os diferentes valores de ocupação assumidos, usando os resultados alcançados com o LS. Os histogramas dos erros de estimação utilizando o filtro LS de ordem 13 para os três cenários de ocupação são mostrados na Fig. 5. É possível observar que a dispersão do erro está associada ao nível de ocupação quando comparamos os histogramas sobrepostos. Além disso é importante destacar que as distribuições do erro de estimação não apresentam um comportamento totalmente simétrico, embora o RMS seja usado como métrica para eficiência do filtro. Apesar disso, em todos os três casos temos as frequências dos erros distribuídos ao redor do zero. Esse fato indica que o método LS pode ser capaz fornecer boas estimativas para o sinal reconstruído. Neste caso, é relevante investigar como a MLP pode aprimorar tal estimativa.

Visto que o fenômeno de empilhamento de sinais introduz componentes não-lineares nos sinais adquiridos, este trabalho explora o uso de ferramentas, tais como as redes MLP, que acessem a informação de ordem superior presente nos sinais. Desta forma, foram treinadas três redes MLP de modo independente, de forma a projetar uma rede corretora para cada condição de ocupação considerada neste trabalho utilizando a configuração apresentada na Seção IV-D. A Fig. 6 mostra as distribuições do erro de estimação da amplitude (energia) para cada condição de ocupação considerada neste trabalho.

Como previsto, à medida que a ocupação aumenta, maior é a participação da rede MLP na estimativa da amplitude, compensando a informação não-linear presente no sinal que não é acessada pelo modelo linear LS. Comparando-se as distribuições, fica claro que a participação da MLP colabora na redução da dispersão dos erros computados, sem efetivamente deslocar os histogramas do zero, o que é desejável. Complementarmente, a Fig. 7 mostra os histogramas das saídas da rede MLP para os casos de 10% e 50% de ocupação, onde é possível observar uma menor dispersão para o caso em que a ocupação também é menor, corroborando a hipótese da relação direta entre a dispersão do erro e o nível de ocupação.

Para efeito de comparação no que tange o erro de estimação do modelo linear LS quando se aplica a correção por MLP, a Fig. 8 apresenta o RMS do histograma do erro de estimação em função da ocupação. Em termos percentuais, a aplicação da correção através das redes MLP reduziu a dispersão do erro de estimação para 10%, 30% e 50% de ocupação em 60%, 40% e 25%, respectivamente. A relação entre ambos os conjuntos de resultados nesta figura demonstra uma tendência em que a estimação por LS assistida por MLP parece sempre levar a valores de RMS do erro de estimação menores do que quando apenas o estimador LS é empregado, mesmo para valores de ocupação que estendem-se ao domínio analisado. Nesta mesma figura, a eficiência do método OF 1 também

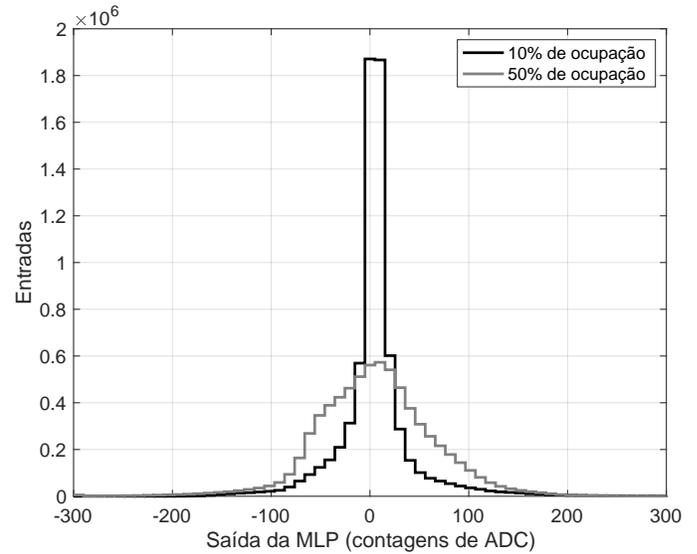


Figura 7: Histogramas das saídas da rede MLP para as ocupações de 10% e 50%.

é mostrada, enquanto a Tab. 1 apresenta os resultados de eficiência (RMS do erro de estimação) para todos os métodos, incluindo a abordagem atualmente utilizada no TileCal (OF 2). Vale destacar que o método OF 2 não utiliza a matriz de covariância do empilhamento e, por esse motivo, seu desempenho é significativamente inferior aos demais métodos.

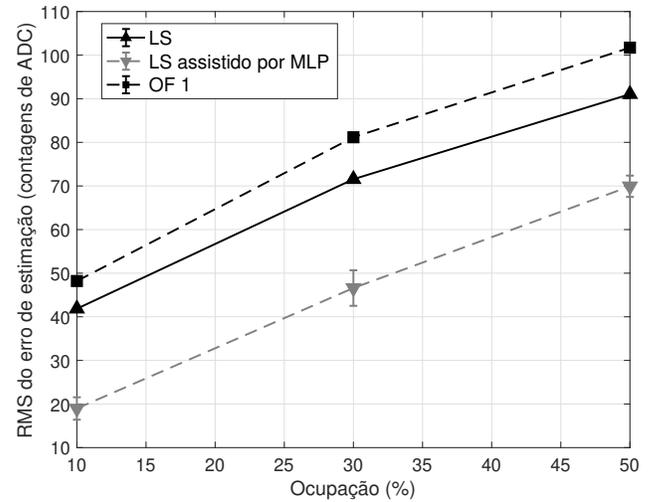


Figura 8: RMS do erro de estimação do filtro LS com e sem a correção por MLP, e do filtro ótimo OF 1.

VI. CONCLUSÕES

O programa de atualização do experimento ATLAS do LHC prevê a substituição da eletrônica de leitura de seus sistemas, incluindo o calorímetro de telhas (TileCal). Neste novo cenário, chamado de HL-LHC, previsto para entrar em operação em 2029, a informação será processada digitalmente

Tabela I: RMS do erro de estimação para cada método avaliado em diferentes condições de ocupação (em contagens de ADC).

	10%	30%	50%
LS	41,9 ± 0,1	71,6 ± 0,1	91,1 ± 0,1
LS+MLP	19,0 ± 2,6	46,6 ± 4,1	69,9 ± 2,5
OF 1	48,2 ± 0,1	81,2 ± 0,1	101,7 ± 0,1
OF 2	194,2 ± 0,3	309,2 ± 0,4	360,0 ± 0,4

de forma ininterrupta. Além disso, a quantidade de eventos gerados a cada colisão aumentará, resultando no efeito indesejado de empilhamento de sinais no sistema de calorimetria do experimento. Desta forma, os métodos que estimam a amplitude (energia) devem responder a cada 25 ns (de acordo com taxa de eventos do LHC). O método atualmente empregado não estima a energia de sinais adjacentes e se apoia na configuração atual da eletrônica, em que numa janela fixa de sete amostras é disponibilizada para calcular a energia do sinal centrado na janela de leitura. Neste trabalho, uma abordagem linear, baseada no método dos mínimos quadrados, é apresentada como solução para o problema de estimação online de energia de forma ininterrupta do TileCal.

Adicionalmente, é proposta uma correção através de redes neurais do tipo MLP que visam compensar as componentes não-lineares introduzidas pelo efeito de empilhamento de sinais. Utilizando um gerador de sinais dedicado a produzir sinais com as características de operação do TileCal durante o HL-LHC, os resultados mostraram que o modelo linear baseado no LS é capaz de reconstruir as energias sem viés. Entretanto, a aplicação da correção neural melhorou a eficiência do método LS de forma substancial, se apresentando como solução promissora para esta aplicação. Ademais, a estratégia combinada proposta neste trabalho atende aos recursos disponíveis na eletrônica nova, a qual será baseada em dispositivos modernos com tecnologia FPGA.

O trabalhos futuros referentes a esta contribuição visam avaliar e comparar modelos de aprendizado profundo na tarefa de estimação da energia do TileCal para a operação durante o HL-LHC.

AGRADECIMENTOS

Os autores agradecem a CAPES, CNPq, FAPEMIG, FA-PERJ 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] T. Akidau, S. Chernyak, and R. Lax, *Streaming Systems: The What, Where, When, and How of Large-Scale Data Processing*. O'Reilly Media, 2018.
- [2] N. Chiedde and on behalf of the ATLAS liquid argon calorimeter group, "Machine learning for real-time processing of atlas liquid argon calorimeter signals with fpgas," *Journal of Instrumentation*, vol. 17, no. 04, p. C04010, apr 2022. [Online]. Available: <https://dx.doi.org/10.1088/1748-0221/17/04/C04010>
- [3] Vol. 1085, no. 2, p. 022008, sep 2018. [Online]. Available: <https://dx.doi.org/10.1088/1742-6596/1085/2/022008>
- [4] L. Evans, "The Large Hadron Collider," *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, vol. 370, no. 1961, pp. 831–858, 2012. [Online]. Available: <https://royalsocietypublishing.org/doi/10.1098/rsta.2011.0453>
- [5] The ATLAS Collaboration, "Observation of a new particle in the search for the Standard Model Higgs boson with the ATLAS detector at the LHC," *Physics Letters B*, vol. 716, no. 1, pp. 1–29, 2012.
- [6] —, "A detailed map of Higgs boson interactions by the ATLAS experiment ten years after the discovery," *Nature*, vol. 607, no. 7917, pp. 52–59, 2022.
- [7] I. Hristova, "Future Plans of the ATLAS Collaboration for the HL-LHC," *Few-Body Systems*, vol. 59, no. 6, p. 137, 2018.
- [8] C. C. Dias, B. S.-M. Peralva, M. Hufnagel, A. Monay e Silva, L. M. Andrade Filho, A. S. Cerqueira, and J. Seixas, "Estimação de Energia Assistida por Redes Neurais para o Calorimetro de Telhas do ATLAS no LHC," in *Anais do 15º Congresso Brasileiro de Inteligência Computacional*, C. J. A. Bastos Filho, H. V. Siqueira, D. D. Ferreira, D. W. Bertol, and R. C. L. Oliveira, Eds. Joinville, SC: SBIC, 2021, pp. 1–8.
- [9] W. Cleland and E. Stern, "Signal processing considerations for liquid ionization calorimeters in a high rate environment," *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, vol. 338, no. 2, pp. 467–497, 1994. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/0168900294913323>
- [10] G. I. Gonçalves, B. S.-M. Peralva, J. M. de Seixas, L. M. de Andrade Filho, and A. S. Cerqueira, "Performance of Optimal Linear Filtering Methods for Signal Estimation in High-Energy Calorimetry," *Journal of Control, Automation and Electrical Systems*, vol. 33, no. 5, pp. 1601–1611, 2022.
- [11] D. C. Montgomery, E. A. Peck, and G. G. Vining, *Introduction to Linear Regression Analysis*. Wiley, 2012.
- [12] The ATLAS Collaboration, "The ATLAS Experiment at the CERN Large Hadron Collider," *Journal of Instrumentation*, vol. 3, no. 08, p. S08003, 2008.
- [13] K. Anderson, A. Gupta, F. Merritt, M. Oreglia, J. Pilcher, H. Sanders, M. Shochet, F. Tang, R. Teuscher, H. Wu, G. Blanchot, M. Cavalliforza, and I. Korolkov, "Design of the front-end analog electronics for the ATLAS tile calorimeter," *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, vol. 551, no. 2-3, pp. 469–476, 2005.
- [14] A. J. Gómez Delegido, "Upgrade of atlas hadronic tile calorimeter for the high luminosity lhc," *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, vol. 1047, p. 167860, 2023. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0168900222011524>
- [15] G. Aad, A.-S. Berthold, T. Calvet, N. Chiedde, E. M. Fortin, N. Fritzsche, R. Hentges, L. A. O. Laatu, E. Monnier, A. Straessner, and J. C. Voigt, "Artificial Neural Networks on FPGAs for Real-Time Energy Reconstruction of the ATLAS LAr Calorimeters," *Computing and Software for Big Science*, vol. 5, no. 1, p. 19, 2021.
- [16] D. O. Damazio, "Signal processing for the ATLAS liquid argon calorimeter: Studies and implementation," in *2013 IEEE Nuclear Science Symposium and Medical Imaging Conference (2013 NSS/MIC)*. IEEE, oct 2013, pp. 1–4.
- [17] G. I. Gonçalves, "Energy Reconstruction Techniques in TileCal Under High Pile-Up Conditions," in *Communications in Computer and Information Science*, 2022, pp. 140–151.
- [18] N. Chiedde, "Machine learning for real-time processing of ATLAS liquid argon calorimeter signals with FPGAs," *Journal of Instrumentation*, vol. 17, no. 04, p. C04010, 2022.
- [19] E. Fullana, J. Castelo, V. Castillo, C. Cuenca, A. Ferrer, E. Higon, C. Iglesias, A. Munar, J. Poveda, A. Ruiz-Martinez, B. Salvachua, C. Solans, R. Teuscher, and J. Valls, "Digital signal reconstruction in the ATLAS hadronic tile calorimeter," in *14th IEEE-NPSS Real Time Conference, 2005*. IEEE, 2005, p. 4 pp. [Online]. Available: <http://ieeexplore.ieee.org/document/1547479/>
- [20] S. M. Kay, *Fundamentals of Statistical Signal Processing: Estimation Theory*. USA: Prentice-Hall, 1993.
- [21] K. Levenberg, "A method for the solution of certain non-linear problems in least squares," *Quarterly of Applied Mathematics*, 1944.
- [22] D. W. Marquardt, "An Algorithm for Least-Squares Estimation of Nonlinear Parameters," *Journal of the Society for Industrial and Applied Mathematics*, vol. 11, no. 2, pp. 431–441, jun 1963. [Online]. Available: <http://epubs.siam.org/doi/10.1137/0111030>