

# Controle do ganho das PMTs do Sistema de Veto do Experimento $\nu$ -Angra baseado em RNA

Guilherme Lopes\*, David Melo, Luan Melo, Igor A Britta, Rafael Nóbrega, Pietro Chimenti, João dos Anjos, Herman Lima, Geraldo Cernicchiaro, Germano Guedes, Ernesto Kemp, Iuri Pepe, and Eduardo Simas

Universidade Federal de Juiz de Fora  
Juiz de Fora-MG, Brasil

{guilherme.lopes,david.melo,luan.melo}@engenharia.ufjf.br,  
igorabritta@gmail.com,ranobr@gmail.com,pietro.chimenti@ufabc.edu.br,  
janjos@on.br,hlima@cbpf.br,geraldocbpf.br,germano.uefs@gmail.com,  
kemp@ifi.unicamp.br,lapo.if@gmail.com,eduardosimas@gmail.com

**Resumo** O experimento  $\nu$ -Angra tem como objetivo construir um dispositivo de detecção de antineutrinos capaz de monitorar a atividade do reator nuclear de Angra dos Reis. O sistema proposto considera um detector operando em superfície, o que faz o mesmo ficar exposto a uma alta taxa de ruído de fundo, principalmente devido a raios cósmicos. Assim sendo, o sistema de veto tem um papel fundamental na viabilidade do experimento. Este artigo propõe uma metodologia inovadora para supervisão da variação do ganho das fotomultiplicadoras no sistema de veto, durante sua operação, baseado no reconhecimento de padrões de raios cósmicos de múons, utilizando redes neurais artificiais.

**Keywords:** Redes Neurais Artificiais, FotoMultiplicadora, Neutrinos Angra, Sistema de Veto.

## 1 Introdução

O principal objetivo do Experimento Neutrinos Angra ( $\nu$ -Angra) é desenvolver um detector de superfície capaz de identificar o fluxo de antineutrinos provenientes do reator nuclear da usina de Angra dos Reis. Conhecendo o fluxo de antineutrinos pode-se monitorar a atividade do reator e estimar a energia térmica produzida em seu núcleo [1]. O experimento também visa estudar a possibilidade de inferir a composição do combustível utilizado no reator a partir da variação do espectro de energia dos neutrinos [2].

Uma particularidade do detector ( $\nu$ -Angra) é o fato de estar localizado na superfície, como mostra a Figura 1, diferente dos demais detectores de antineutrinos [3], que estão localizados abaixo do solo. Essa característica faz com

---

\* Este trabalho foi apoiado por várias agências de fomento, através de uma série de projetos de financiamento. A Colaboração Angra reconhece o apoio do MCTI, CNPq, FINEP e as seguintes agências de pesquisa estaduais: FAPESP, FAPEMIG e FAPERJ.

que o detector fique exposto a uma alta taxa de eventos gerados a partir de raios cósmicos, fazendo com que o sistema de veto tenha a necessidade de ser altamente eficiente, com o objetivo de identificar os raros eventos de neutrinos. Para que este sistema opere de forma eficiente e confiável é necessário garantir a correta calibração das PMTs (do inglês, *Photomultiplier Tube*). Este artigo descreve o desenvolvimento de um algoritmo de reconhecimento de padrões para monitorar o ganho das PMTs do sistema de veto.



**Figura 1.** Detector Neutrinos Angra ( $\nu$ -Angra)

Na Seção 2 serão mostrados a metodologia de trabalho e o ambiente no qual a pesquisa está inserida. Já a Seção 3 define os algoritmos utilizados para estimação do ganho das PMTs. Logo depois, na Seção 4 serão apresentados o resultados alcançados e, finalmente, na Seção 5 as conclusões.

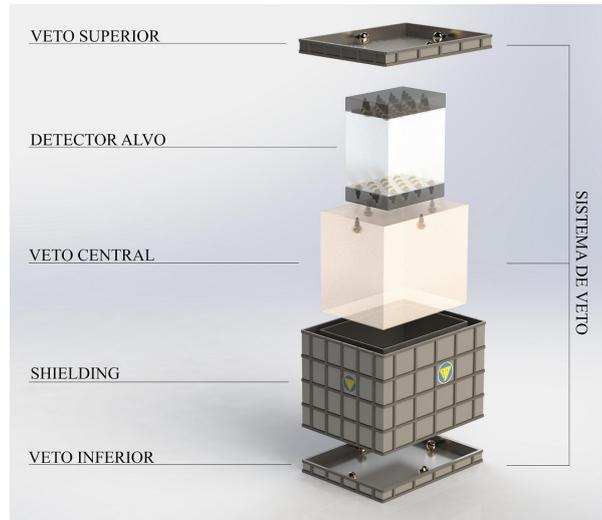
## 2 Metodologia

Com o intuito de fornecer um melhor conhecimento do ambiente onde este trabalho foi desenvolvido, esta seção apresentará o detector e suas particularidades de construção, bem como, a estratégia utilizada para realizar a aquisição dos dados utilizados nesse trabalho.

### 2.1 Detector ( $\nu$ -Angra)

O detector  $\nu$ -Angra será instalado ao lado da cúpula do reator nuclear Angra II e foi projetado com 4 subsistemas principais: o detector alvo, composto por 32 PMTs; o veto central, composto por 4 PMTs; as duas tampas, cada uma com 4 PMTs; e o sistema de *Shielding*.

As dimensões do detector inteiro são  $2,75\text{m} \times 2,10\text{m} \times 2,42\text{m}$  e os vetos superior e inferior possuem as seguintes dimensões:  $2,75\text{m} \times 2,10\text{m} \times 0,25\text{m}$ .



**Figura 2.** Vista explodida do modelo computacional do Detector ( $\nu$ -Angra)

## 2.2 Aquisição de Dados

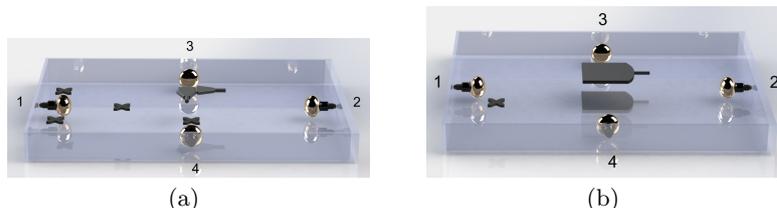
Para esta análise utilizou-se medidas feitas no veto superior, obtidas da eletrônica de aquisição do Detector ( $\nu$ -Angra) [4] [5], realizadas no Centro Brasileiro de Pesquisas Físicas (CBPF) localizado no Rio de Janeiro.

Para os algoritmos de reconhecimento, devido a limitação prática, as medidas foram realizadas em um quarto (1/4) do detector, aproveitando a simetria do detector. Pás cintiladoras foram colocadas em diferentes posições, funcionando como *trigger* para os eventos, utilizando uma lógica *AND*, ou seja, fazendo com que somente os eventos que interagiram com as duas pás cintiladoras fossem analisados. Foram realizados dois conjuntos de medidas:

- Utilizando pás pequenas (14x14) cm, acima do detector, como mostrado na Figura 3(a);
- Utilizando pás grandes (40x40) cm, uma acima e outra abaixo do detector, de forma que o detector fique localizado entre as pás, como mostrado na Figura 3(b).

Os eventos que ocorrem na posição central foram definidos como sinal e os eventos que passaram nas posições marcadas com X nas Figuras 3(a) e 3(b) foram definidos como ruído. Cada evento possui quatro dimensões, que representam a energia detectada por cada PMT. Esta energia é diretamente proporcional a amplitude do pulso característico na saída das PMTs, que é originado da conversão de energia luminosa liberada pelos fótons.

Neste contexto, para detectar a variação do ganho é necessário definir um modelo de referência, que nesse caso será extraído dos eventos aquisitados com



**Figura 3.** Descrição do padrão de aquisição das medidas no veto superior. (a) utilizando as pás pequenas e (b) utilizando as pás grandes.

as pás cintiladoras na posição central, com isso será possível perceber a variação desse modelo e estimar o ganho. Portanto, para identificar esses eventos teremos que utilizar um método de classificação que apresente uma boa performance na seleção dos eventos centrais e ainda possua uma alta taxa de rejeição dos eventos que serão considerados ruído de fundo.

### 3 Desenvolvimento

Nessa seção, será descrito o método de classificação escolhido para este trabalho e como foi feita a sua configuração visando otimizar a performance do mesmo. Além disso, será apresentado o algoritmo de monitoramento do ganho das PMTs e seu equacionamento.

#### 3.1 Método de Classificação

Para o presente trabalho, foi utilizado como método de classificação a Rede Neural Artificial (RNAs) [6], que consiste em um sistema distribuído paralelamente compostos por nodos, que são unidades de processamento simples interligadas por diversas conexões, na maioria das vezes unidirecionais. Estas conexões se associam a pesos que servem para ponderar a entrada recebida por cada neurônio.

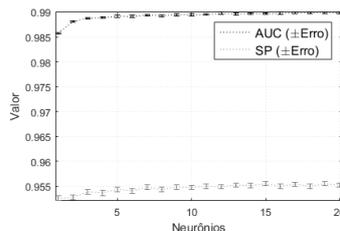
Os dados estudados neste trabalho possuem características que não são linearmente separáveis. Segundo [7], solução de problemas não linearmente separáveis exigem RNAs com uma ou mais camadas escondidas. Com isso, foi escolhida a topologia Perceptron de múltiplas camadas (do inglês, Multi Layer Perceptron, MLP). Um estudo anterior [8] foi realizado comparando o classificador linear com a RNA Perceptron múltiplas camadas, aplicado aos dados utilizados neste artigo.

Para essa proposta utilizou-se o algoritmo de treinamento *backpropagation*, ou Regra Delta generalizada, que basicamente é um procedimento de aprendizagem que utiliza vetores para mapear determinado conjuntos de entradas para um conjunto de saída. Os pesos são iniciados de forma aleatória e a cada processo iterativo é corrigido de forma a minimizar as diferenças entre a saída atual e a saída esperada. O sinal de erro resultante desta diferença é retro propagado através da rede viabilizando o ajuste dos pesos. Este processo é repetido até

que os valores de saída sejam próximos dos desejados. Após esse procedimento é gerada uma função que relaciona os dados de entrada com a saída, na maioria das vezes esta função não é linear.

O algoritmo de treinamento *backpropagation* pode ter seu desempenho afetado caso ocorra uma escolha de pesos errados, onde o algoritmo pode convergir para um mínimo local. Nesse contexto, visando evitar problemas durante a etapa de treino, a validação cruzada (*k-fold cross-validation*) foi utilizada. Segundo [9], a validação cruzada tem como objetivo garantir a generalização do modelo proposto, evitando problemas como super-aprendizagem ou super-ajuste. Essa técnica consiste em dividir os dados devidamente rotulados em k seções e efetuar uma rotação nesses dados a cada iteração do algoritmo. Em outras palavras, uma nova combinação dos dados de entrada da RNA será gerada a cada iteração, sendo que a variação ou rotação desses dados ocorre k vezes.

Para calcular o número de neurônios na camada escondida, foram utilizados o critério SP (do inglês, *Sum-Product*) [10] e a AUC (do inglês, *Area Under the Curve*) [11]. A Figura 4 mostra o desempenho da RNA com a variação do número de neurônios na camada escondida. Considerando uma boa margem de segurança o valor escolhido foi de 15 neurônios.



**Figura 4.** Influência do número de neurônios na eficiência da RNA.

Após estas análises, os parâmetros definidos para a RNA foram, 1 camada escondida com 15 neurônios, foram feitas 10 validações cruzadas, com 20 inicializações randômicas dos pesos em cada validação.

### 3.2 Algoritmo de Monitoramento do Ganho das PMTs

O princípio básico do algoritmo de monitoramento do ganho das PMTs é definir os parâmetros de referência através dos eventos de sinal na posição central do detector, como mostrado na Equação 1.

$$A_i = \frac{\sum_{k=1}^n SignalTruth_{kj}}{n} \tag{1}$$

onde  $A_i$  é a média dos dados adquiridos na posição central em cada PMT,  $n$  é o número de eventos e  $k$  é o número da PMT.

Somando os valores de  $A_i$  para cada PMT e dividindo cada  $A_i$  por esta soma obtemos a relação que representa cada média em relação a soma das médias, dada pela Equação 2. Ou seja, nesta etapa será obtido um valor de referência para cada PMT, que representa qual a contribuição média para todos os eventos de cada PMT em relação a todas as PMTs.

$$M_i = \frac{A_i}{\sum_{k=1}^4 A_k} \quad (2)$$

Seja  $a_i$  a média dos dados classificados como sinal pela RNA, definido pela equação 3.

$$a_i = \frac{\sum_{k=1}^n \text{SignalRNA}}{n} \quad (3)$$

O ganho portanto pode ser definido por:

$$G_i = \frac{a_i}{\sum_{k=1}^4 A_k M_i} \quad (4)$$

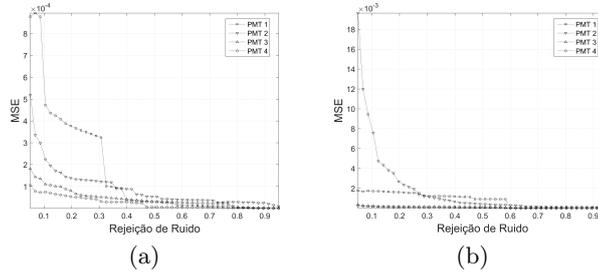
Assim, o ganho das PMTs será variado no intuito de observar o comportamento e o desempenho da RNA em relação a estas variações.

## 4 Resultados

Nesta seção, serão mostrados os resultados em diferentes perspectivas, com o propósito de avaliar tanto a performance quanto a coerência de toda sequência lógica desenvolvida. Primeiro, será feita uma análise do quanto o algoritmo de monitoramento de ganho é influenciado pelo aumento da rejeição de ruído. E por fim, será mostrado o funcionamento do algoritmo em situações onde os ganhos variam proporcional e desproporcionalmente.

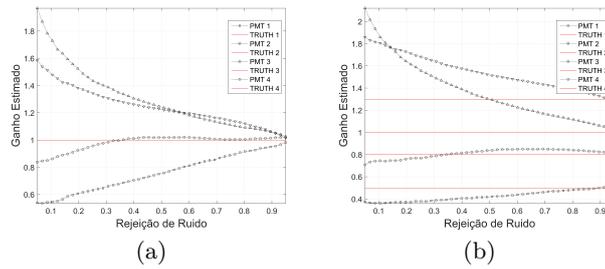
### 4.1 Rejeição de Ruído

Algoritmos de reconhecimento de padrão fornecem a possibilidade de ajuste do seu ponto de operação, ou seja, podem ser ajustados com o auxílio de curvas, como a ROC, que evidenciam o *trade-off* entre eficiência e rejeição de ruído. Nesta análise, em específico, faz-se necessário amostras bastante puras do conjunto que representa nosso sinal, como explicado na seção 2. As Figuras 5(a) e 5(b) mostram o MSE (do inglês, *Mean Square Error*) [12] entre a PDF do sinal classificado pela RNA e a PDF *truth* de sinal. Nota-se que a medida em que aumenta a rejeição de ruído o MSE diminui seu valor, evidenciando que a PDF dos eventos classificados pela RNA está ficando cada vez mais parecida com a PDF *truth*, nossa amostra de sinal está ficando cada vez mais pura com o aumento da rejeição de ruído.



**Figura 5.** Variação do MSE ao aumentar a rejeição de ruído de fundo. (a) PMTs calibradas com ganho igual a 1 e (b) PMTs descalibradas  $PMT_1 = 0.5$ ;  $PMT_2 = 1.3$ ;  $PMT_3 = 1$ ;  $PMT_4 = 0.8$ .

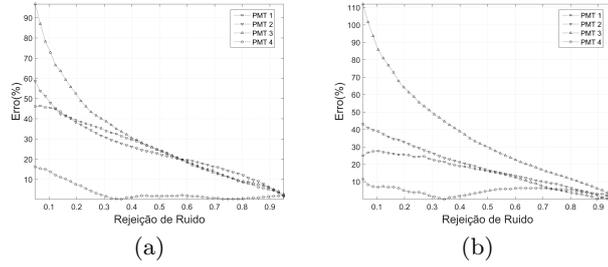
A melhora na representação da PDF do sinal proporciona uma melhora na estimação do ganho do algoritmo de monitoramento. As Figuras 6(a) e 6(b) mostram como a convergência do algoritmo de monitoramento está relacionado ao aumento da rejeição do ruído.



**Figura 6.** Estimação do ganho das PMTs ao aumentar a rejeição de ruído de fundo. (a) PMTs calibradas com ganho igual a 1 e (b) PMTs descalibradas  $PMT_1 = 0.5$ ;  $PMT_2 = 1.3$ ;  $PMT_3 = 1$ ;  $PMT_4 = 0.8$ .

Logo, podemos verificar que o erro percentual de estimação reduz drasticamente com o aumento da rejeição do ruído. Com 5% de rejeição de ruído o erro máximo na Figura 7(a) é de  $\sim 97\%$ , com rejeição de ruído de 95% o erro máximo caiu para  $\sim 9\%$ . A Figura 7(b) apresenta a mesma tendência 112% de erro máximo com rejeição de ruído de 5% e  $\sim 9\%$  de erro máximo com  $\sim 95\%$  de rejeição.

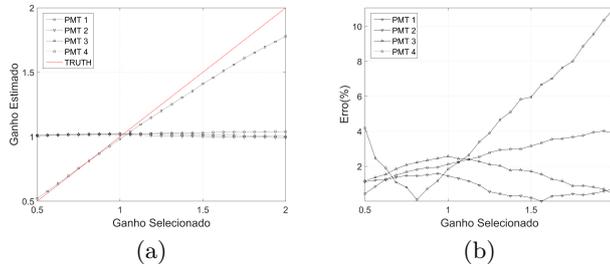
Devido a estatística disponível nesta análise a rejeição de ruído das análises posteriores foi ajustada para 95%.



**Figura 7.** Erro na estimação do ganho das PMTs ao aumentar a rejeição de ruído de fundo. (a) PMTs calibradas com ganho igual a 1 e (b) PMTs descalibradas  $PMT_1 = 0.5$ ;  $PMT_2 = 1.3$ ;  $PMT_3 = 1$ ;  $PMT_4 = 0.8$ .

#### 4.2 Variação Proporcional do Ganho

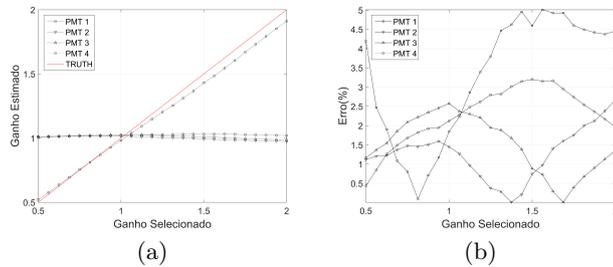
Após definir a rejeição de ruído é importante analisar, na perspectiva de ganho, uma região confortável de funcionamento para o algoritmo de monitoramento. Então, como primeiro teste foi variado o ganho da metade até o dobro do ganho de referência, sendo situações superdimensionadas para o experimento real. A Figura 8(a) mostra o teste feito na  $PMT_1$ , variando o ganho de 0,5 a 2 e analisando quanto o algoritmo de monitoramento estimava de ganho. As demais PMTs foram mantidas com o ganho de referência = 1. Na Figura 8(b) observamos que ao diminuir ou aumentar o ganho na  $PMT_1$  a tendência é o aumento do erro de medida, enquanto as outras mantêm uma tendência de flutuação menor.



**Figura 8.** Análise da variação artificial do ganho da  $PMT_1$ , utilizando o algoritmo proposto (com saturação). (a) Estimação do ganho e (b) Erro de estimação.

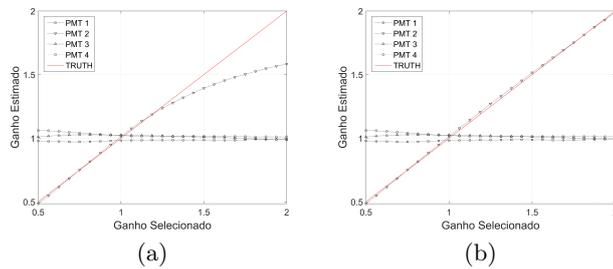
É interessante notar que o aumento do ganho distorce mais a estimação do que a diminuição. Este fato ocorre devido a NDAQ (do inglês, Neutrino Data Acquisition System) [5] saturar em 127 ADC, confundindo o reconhecimento de padrão da RNA. Um teste foi feito retirando da simulação a saturação, como mostra a Figura 9(a), e a saturação na estimação do ganho não foi tão acentuada

como na Figura 8(a), e o erro de estimação apresentado na Figura 9(b) não ultrapassou 5%.



**Figura 9.** Análise da variação artificial do ganho da  $PMT_1$ , utilizando o algoritmo proposto (sem saturação). (a) Estimação do ganho e (b) Erro de estimação.

Outro fato que fortalece esse entendimento é perceber que as PMTs 2 e 4, que estão mais próximas das pás cintiladoras na posição central, como mostrado na Figura 3(b), deveriam sofrer mais com a saturação, como mostra a Figura 10(a) e o efeito da remoção da saturação, Figura 10(b), ficaria mais evidente.

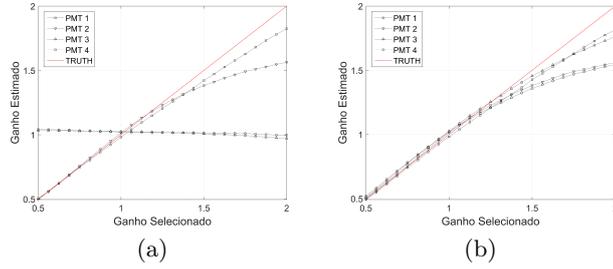


**Figura 10.** Estimação do ganho da  $PMT_2$  com a variação do ganho da mesma artificialmente, utilizando o algoritmo proposto. (a) Com saturação e (b) Sem saturação.

Testes foram feitos variando o ganho de 2 PMTs, Figura 11(a), e 4 PMTs, Figura 11(b), ao mesmo tempo, sendo observado o mesmo padrão. Saturação mais acentuada por volta de 1.5 de Ganho, com erro de abaixo de 10% nos dois casos. Quando o ganho chega a 2 o erro fica acima de 20% nos dois casos.

### 4.3 Variação do Ganho de forma desproporcional

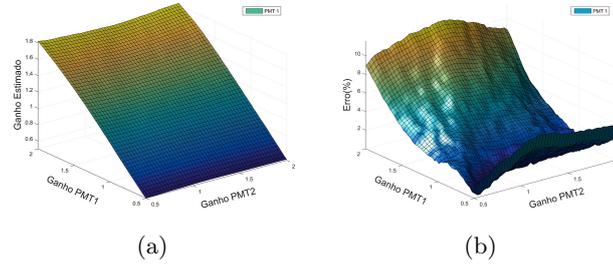
Na tentativa de avaliar o funcionamento dos algoritmos em uma das piores realidades possíveis, em que fosse possível visualizar graficamente, foi feito um teste



**Figura 11.** Estimação do ganho das PMTs, utilizando o algoritmo proposto. (a) variando o ganho de 2 PMTs na mesma proporção e (b) variando o ganho de 4 PMTs na mesma proporção, simultaneamente.

variando de forma desproporcional os ganhos, no intervalo de 0.5 a 2, em duas PMTs, sendo avaliada a estimação nas 4 PMTs nessa realidade.

A Figura 12(a) mostra o ganho que o algoritmo de monitoramento consegue estimar na  $PMT_1$  enquanto o ganho da  $PMT_1$  e  $PMT_2$  variam, em combinações diferentes de 0.5 a 2 de ganho. Consegue-se perceber o mesmo problema visto nas análises anteriores, existe uma saturação quando o ganho da  $PMT_1$  aumenta, sendo que o erro de estimação, Figura 12(b), chega a 11.5%.

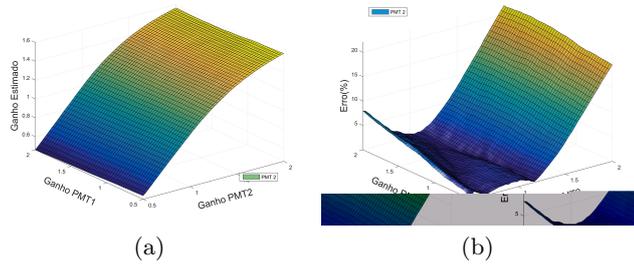


**Figura 12.** Análise da  $PMT_1$  com a variação artificial do ganho das PMTs 1 e 2, utilizando o algoritmo proposto. (a) Estimação do ganho e (b) Erro de estimação.

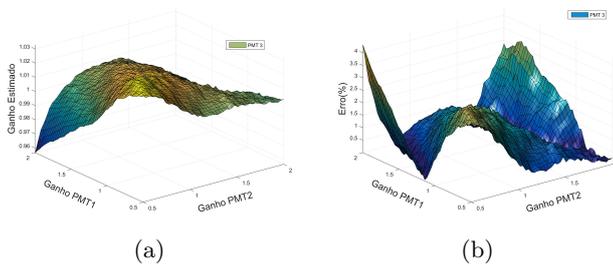
Ao verificar a estimação na  $PMT_2$ , Figura 13(a), observou-se uma saturação mais acentuada do que a  $PMT_1$ , devido a posição da PMT em relação as pás cintiladoras. A Figura 13(b) mostra que o erro máximo é de  $\sim 21.5\%$ .

A  $PMT_3$  sofre pouco com a variação desproporcional do ganho das PMTs 1 e 2, conseguindo manter seu ganho de referência próximo a 1, como mostra a Figura 14(a). O erro máximo percebido na  $PMT_3$  foi de aproximadamente 4.3%, mostrado na Figura 14(b).

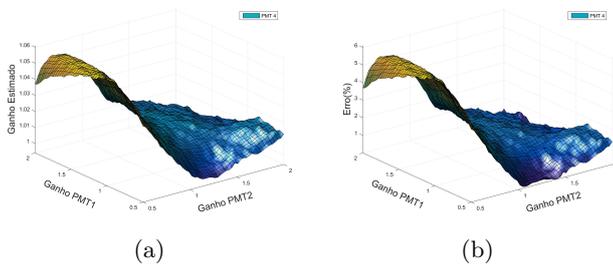
A  $PMT_4$ , da mesma forma, consegue manter a estimação do ganho próximo a referência = 1, Figura 15(a). Com erro de  $\sim 6.1\%$ , mostrado na Figura 15(b).



**Figura 13.** Análise da  $PMT_2$  com a variação artificial do ganho das PMTs 1 e 2, utilizando o algoritmo proposto. (a) Estimação do ganho e (b) Erro de estimação.



**Figura 14.** Análise da  $PMT_3$  com a variação artificial do ganho das PMTs 1 e 2, utilizando o algoritmo proposto. (a) Estimação do ganho e (b) Erro de estimação.



**Figura 15.** Análise da  $PMT_4$  com a variação artificial do ganho das PMTs 1 e 2, utilizando o algoritmo proposto. (a) Estimação do ganho e (b) Erro de estimação.

## 5 Conclusão

Este trabalho apresentou o atual status de desenvolvimento de um algoritmo de monitoramento do ganho das fotomultiplicadoras do experimento  $\nu$ -Angra. De uma maneira geral o algoritmo se mostra resiliente na estimação do ganho em uma faixa de 0.5 a 1.5 do ganho de referência, com erro máximo de estimação

menor do que 10% em todos os testes, ao variar o ganho proporcionalmente ou desproporcionalmente, em uma ou mais Fotomultiplicadoras simultaneamente.

Foi possível perceber que a saturação dos eventos, ocasionada pelo sistema de aquisição de dados (NDAQ), é um dos responsáveis pela perda de performance do algoritmo de monitoramento, levando a hipótese de se repensar sobre o excursionamento do sinal elétrico no intuito de amenizar o efeito da saturação.

O algoritmo de monitoramento de ganho, com a atual configuração, mostra-se capaz de estimar variações do ganho com níveis de erro aceitáveis dentro das realidades criadas neste trabalho, mostrando-se uma importante ferramenta na manutenção da qualidade, a curto ou longo prazo, dos eventos gerados pelo experimento  $\nu$ -Angra. Este fato nos abre a perspectiva de estudos futuros mais aprofundados, utilizando algoritmos de simulação do sinal elétrico proveniente de partículas criadas em *Geant4*, onde espera-se um maior controle das posições onde as partículas irão interagir com o detector.

## Referências

1. J. Anjos, T. Abrahão, T. Alvarenga, L. Andrade, G. Azzi, A. Cerqueira, P. Chimenti, J. Costa, T. Dornelas, P. Farias *et al.*, “Using neutrinos to monitor nuclear reactors: the angra neutrino experiment, simulation and detector status,” *Nuclear and Particle Physics Proceedings*, vol. 267, pp. 108–115, 2015.
2. T. A. Mueller, D. Lhuillier, M. Fallot, A. Letourneau, S. Cormon, M. Fechner, L. Giot, T. Lasserre, J. Martino, G. Mention *et al.*, “Improved predictions of reactor antineutrino spectra,” *Physical Review C*, vol. 83, no. 5, p. 054615, 2011.
3. F. Boehm, J. Busenitz, B. Cook, G. Gratta, H. Henrikson, J. Kornis, D. Lawrence, K. Lee, K. McKinny, L. Miller *et al.*, “Final results from the palo verde neutrino oscillation experiment,” *Physical Review D*, vol. 64, no. 11, p. 112001, 2001.
4. T. Alvarenga, J. Anjos, G. Azzi, A. Cerqueira, P. Chimenti, J. Costa, T. Dornelas, P. Farias *et al.*, “Readout electronics validation and target detector assessment for the neutrinos angra experiment,” *Nuclear Instruments and Methods in Physics Research Section A*, vol. 830, pp. 206–213, 2016.
5. T. Dornelas, F. Araújo, A. Cerqueira, J. Costa, and R. Nóbrega, “Front-end design and characterization for the  $\nu$ -angra nuclear reactor monitoring detector,” *Journal of Instrumentation*, vol. 11, no. 07, p. P07018, 2016.
6. H. Simon, “Redes neurais—princípios e prática,” 2001.
7. A. d. P. Braga, A. Carvalho, and T. B. Ludermir, *Redes neurais artificiais: teoria e aplicações*. Livros Técnicos e Científicos, 2000.
8. L. Melo, D. M. Souza, I. A. Costa, R. A. Nóbrega *et al.*, “A cosmic rays based method to detect and correct pmt gain variations for the  $\nu$ -angra veto system.”
9. R. Kohavi *et al.*, “A study of cross-validation and bootstrap for accuracy estimation and model selection,” in *Ijcai*, vol. 14, no. 2. Stanford, CA, 1995, pp. 1137–1145.
10. D. C. Teles, F. Batista, E. E. de Souza, J. M. de Seixas *et al.*, “Sistema neural segmentado de detecção online de elétrons utilizando pré-processamento estatístico.”
11. A. P. Bradley, “The use of the area under the roc curve in the evaluation of machine learning algorithms,” *Pattern recognition*, vol. 30, no. 7, pp. 1145–1159, 1997.
12. D. M. Allen, “Mean square error of prediction as a criterion for selecting variables,” *Technometrics*, vol. 13, no. 3, pp. 469–475, 1971.