



Um comparativo entre a utilização de redes neurais perceptron e redes neurais profundas na identificação de radionuclídeos em espectrometria gama

Otero, A. G. L.^a, Potiens Júnior, A. J.^a, Marumo, J. T.^a

^a Instituto de Pesquisas Energéticas e Nucleares, IPEN-CNEN/SP, Av. Prof. Lineu Prestes, 2242 – Cidade Universitária – CEP 05508-000 São Paulo – SP – Brasil

aglotero@ipen.br

RESUMO

Apresentamos os resultados da comparação entre uma Rede Neural Profunda e uma Rede Neural Perceptron na classificação de espectros gama obtidos utilizando um detector de germânio hiper-puro. Utilizando dados de diversas fontes seladas (Am-241, Ba-133, Cd-109, Co-57, Co-60, Cs-137, Eu-152, Mn-54, Na-24, and Pb-210) foram gerados uma lista extensa de espectros para treino e validação contendo, respectivamente, 500 e 160 espectros, onde foram mesclados até três radionuclídeos em um único espectro. Depois de 250 épocas de treino foram validadas a exatidão de cada um dos modelos utilizando o conjunto de validação. O modelo de rede neural profunda obteve uma exatidão de classificação de 96,25% enquanto a rede neural perceptron obteve uma exatidão de 80,62%. Os resultados mostram um desempenho robusto e consistentemente melhor das redes neurais profundas, frente as redes neurais perceptron.

Keywords: redes neurais; redes neurais profundas; caracterização; espectrometria gama

ABSTRACT

We present the results of the comparison between a deep neural network and a perceptron neural network in the classification of gamma spectra obtained using a hyper-pure germanium detector. Using data from several sealed sources (Am-241, Ba-133, Cd-109, Co-57, Co-60, Cs-137, Eu-152, Mn-54, Na-24, and Pb-210) A set of training and validation was created containing 500 and 160 spectra each, where up to three radionuclides were mixed into a single spectrum. After 250 training epochs, the accuracy of each model was validated using the validation set. The deep neural network model achieved a 96.25% accuracy rate while the perceptron neural network achieved an 80.62% accuracy rate. Results show robust and consistently better performance of deep neural networks, comparing to the perceptron neural network.

Keywords: neural networks, deep neural networks, characterization, gamma spectrometry

1. INTRODUÇÃO

A identificação de radionuclídeos em espectrometria gama é uma etapa necessária do processo de caracterização de rejeitos radioativos[01], em que um software analisa o espectro obtido por um detector e através de alguma técnica de análise, informa quais são os radionuclídeos presentes no espectro. Diversas técnicas podem ser empregadas nesta tarefa, dentre elas, a utilização de redes neurais artificiais.

Uma rede neural artificial é uma técnica de inteligência artificial que procura mimetizar o funcionamento do cérebro biológico, onde uma entrada de dados é processada pelos neurônios e suas conexões para a produção de uma saída[02][03]. Esta técnica tem sido empregada em diferentes domínios ultrapassando o desempenho de seres humanos nestas mesmas tarefas [04][05][06][07][08][09].

No caso de identificação de radionuclídeos a saída da rede neural é a probabilidade de um determinado radionuclídeo estar presente no espectro. Diversos estudos exploraram a aplicação de redes neurais do tipo *perceptron* na identificação de radionuclídeos em espectrometria gama com resultados interessantes, entretanto, devido às limitações de hardware e/ou software à época dos estudos, o espectro era previamente tratado para reduzir o seu tamanho, possibilitando assim o treino e utilização do modelo[10][11][12][13].

Com o advento de novos algoritmos e novos tipos de hardware, como por exemplo as unidades de processamento gráficas (GPU), deu-se início a uma onda de desenvolvimento na área das redes neurais, onde é possível treinar redes com muito mais neurônios, e com muito mais dados. Atualmente o treinamento pode ser feito em pequenos lotes do conjunto de treino por vez, em vez de utilizar o conjunto de treino inteiro em memória. Essa nova geração de redes neurais recebe o nome de redes neurais profundas (*deep neural networks*)[14].

Neste estudo, comparamos o desempenho de uma rede neural do tipo *perceptron* contra o desempenho de uma rede neural profunda, a fim de identificar oportunidades de melhorias na identificação de radionuclídeos em espectrometria gama.

2. MATERIAIS E MÉTODOS

Utilizando um conjunto de fontes seladas (Am-241, Ba-133, Cd-109, Co-60, Cs-137, Eu-152, Mn-54, Na-24 e Pb-210) foram realizadas diversas medições com um detector do tipo HPGe a fim de criar um conjunto de dados para o treino das redes neurais. Foi desenvolvido um script para combinar os diversos espectros de maneira aleatória, a fim de criar espectros com mais de um radionuclídeo, possibilitando assim, simular uma situação onde um tambor de rejeito contivesse mais de um radionuclídeo. Esse conjunto de espectros foi dividido em dois: um conjunto utilizado no treino do modelo, e outro para validação do desempenho do treino.

Os espectros foram combinados através da soma de leituras diferentes com a adição de um ruído gaussiano aleatório, embora essa situação seja uma simplificação de uma situação real com diversas fontes combinadas, acreditamos que é um passo necessário para validar a hipótese do uso de redes neurais profundas, para posteriormente estender a pesquisa para situações mais complexas.

Com os conjuntos de treino e validação prontos, codificamos uma rede neural *perceptron* e uma rede neural profunda, treinamos ambas as redes, e comparamos o desempenho de ambas quanto ao erro de classificação e o tempo de treino.

A rede neural *perceptron* é a mesma utilizada em um estudo anterior[13], contendo três camadas com 1024, 512 e 10 neurônios, respectivamente. A rede neural profunda utiliza uma arquitetura amplamente utilizada em classificação de imagens[15], chamada VGG-19.

2.1. Configuração das redes

As configurações das redes utilizadas são sumarizadas na Tabela 1.


Tabela 1: Configuração das redes utilizadas

Parâmetro	Arquitetura	
	Perceptron	Deep Learning (VGG19)
Função de ativação na última camada	Sigmoid	Sigmoid
Número de camadas	3	26
Número de épocas no treino	250	250
Software utilizado na criação do modelo	scikit-learn[16]	Keras/Tensorflow[17]
Hardware utilizado para processamento	CPU (Central Processing Unit)	GPU (Graphical Processing Unit)

2.2. Geração de dados de treino e validação

As medições das 10 fontes seladas foram utilizadas para a geração de quinhentas instâncias de treino e cento e sessenta instâncias de validação, para simular espectros com mais de um radionuclídeo. Foram combinadas aleatoriamente até três radionuclídeos diferentes, o número de combinações foi escolhido arbitrariamente. Essa combinação foi possível pois as medições das fontes seladas foram realizadas nas mesmas condições.

A rede neural *perceptron* recebe os dados de leitura na forma de um vetor, já a rede neural profunda recebe os dados de leitura na forma e uma imagem mono canal, conforme descrito na Figura 1. Aqui há apenas uma reorganização do vetor original para o formato de uma imagem com 128 por 128 pixels.

Figura 1: Visualizações do Espectro de Am-241.

2.3 Pré-processamento dos dados de entrada

Para a rede neural do tipo perceptron os dados de entradas foram normalizados para o intervalo entre zero e um, dividindo cada espectro pelo seu valor máximo, esse pré-processamento é necessário pois as redes neurais perceptron são sensíveis a valores de entrada extremos que podem zerar a saída da função Sigmoid.

2.4. Treino

As redes foram treinadas por 250 épocas, isto é, a rede recebeu 250 vezes o conjunto de treino completo para atualização dos parâmetros da rede.

2.5. Avaliação dos modelos

A avaliação dos modelos foi realizada utilizando a função “top_k_categorical_accuracy” do pacote Keras. Essa função avalia a exatidão de um classificador para “k” categorias, calculando qual a exatidão das previsões dada as “k” primeiras classes, por exemplo, para um determinado problema existem cinco classes não mutualmente excludentes: {a, b, c, d, e}, em uma determinada instância o valor verdadeiro de classificação é {a, e}, se um modelo prevê que as classes {a, c}, o valor da métrica top_k_categorical_accuracy com um k=1 é 100%, para k=2 é 50% e para k=3 é 33,33%. O objetivo da métrica é medir a exatidão entre a previsão do modelo e as possíveis classes que uma instância pode assumir, fixando o número máximo de classes que se deseja avaliar.

Um valor comum utilizado em competições de classificação de imagens é k=5, nestas competições existem em torno de duzentas classes, então avaliam-se as cinco primeiras com a maior probabilidade.

Nosso conjunto de dados foi construído contendo até 3 radionuclídeos por instância, portanto nosso parâmetro “k” é igual a 3.


3. RESULTADOS E DISCUSSÃO

A reprodução da rede neural *perceptron* foi capaz de atingir uma exatidão de classificação de 80,62%, a rede neural profunda foi capaz de atingir uma exatidão de classificação de 96,25%, ambas no conjunto de teste, ou seja, dados nunca antes vistos pelo modelo.

Mesmo utilizando outra plataforma de software e hardware, a reprodução da rede *perceptron* alcançou o nível de desempenho apresentado no trabalho original[13], mostrando a robustez da técnica original. A rede neural profunda desenvolvida neste trabalho utiliza uma plataforma de software e hardware nova, ao utilizar mais camadas a capacidade de generalização da rede aumenta e com isso a exatidão.


A evolução do treinamento é ilustrada na Figura 2, a rede neural *perceptron* tem um nível de erro maior que a rede neural profunda, apesar de apresentar uma linha de evolução constante a cada iteração de treino, após 250 épocas, apresenta um resultado final pior que a rede neural profunda. A rede neural profunda apresenta um nível de erro baixo desde o início do treino, e após 200 épocas converge para um nível próximo de zero, permanecendo neste nível até atingir 250 épocas.

Figura 2: Evolução do treino das redes neurais.
Evolução do treinamento das duas redes neurais



Embora a rede neural *perceptron* seja menor, e consequentemente utilizaria menos recursos computacionais para as previsões, ela é ultrapassada em desempenho pela rede neural profunda em 19,39% o que justifica o uso desta, mesmo utilizando mais recursos computacionais.

Além da avaliação de desempenho no consulto de validação, foi realizado a leitura de um espectro de uma fonte tríplice de calibração contendo Am-214, Cs-137 e Co-60, esse espectro também foi obtido na mesma geometria das demais fontes. O espectro e a imagem monocanal são exibidos na Figura 3.

Figura 3: Espectro e imagem mono canal da fonte Am-241/Cs-137/Co-60 de calibração.

Os resultados da previsão dos modelos são sumarizados na Tabela 2.

Tabela 2: top_k_categorical_accuracy dos modelos para o espectro da fonte tríplice

Métrica	Arquitetura	
	Perceptron	Deep Learning (VGG19)
top_k_categorical_accuracy	70%	100%

Para entendermos melhor a saída do modelo precisamos analisar a saída completa dos modelos, a Tabela 3 sumariza a saída de probabilidade para cada radionuclídeo. Em uma previsão exata, somente os radionuclídeos que compõe o espectro devem apresentar valores na saída do modelo, utilizamos o limite de 50% para determinar se um radionuclídeo está contido no espectro avaliado pelo modelo.

Podemos perceber que a rede neural profunda além de prever corretamente todos os radionuclídeos contidos no espectro não apresenta probabilidades para nenhum outro radionuclídeos, já a rede *perceptron* é capaz de identificar corretamente dois de três, entretanto ela apresenta probabilidades para todos os radionuclídeos, além de classificar, erroneamente, como contido no espectro Co-57.

Tabela 3: Saída completa de cada modelo

Radionuclídeo	Probabilidade de conter o radionuclídeo	
	<i>Perceptron</i>	<i>Deep Learning (VGG19)</i>
Am-241	72,42%	99,99%
Ba-133	26,45%	0.00%
Cd-109	18,70%	0.00%
Co-57	62,23%	0.00%
Co-60	36,42%	99,98%
Cs-137	70,51%	100.00%
Eu-152	13,47%	0.00%
Mn-54	22,34%	0.00%
Na-22	29,18%	0.00%
Pb-210	17,34%	0.00%

Devido a da capacidade de generalização da rede neural profunda é possível treinar a rede com espectros gerados a partir de diferentes configurações de detectores e calibrações, de modo que a classificação do modelo seja independente da calibração do equipamento utilizado para a captura dos dados, melhorando assim o processo de caracterização.

4. CONCLUSÃO

A utilização de uma rede neural profunda para identificação de radionuclídeos em espectrometria gama mostrou-se robusta e apresentou um incremento de performance com relação à rede neural do tipo *perceptron*. Cabe salientar que a rede neural profunda utilizou os dados do espectro sem qualquer pré-processamento, enquanto a rede neural *perceptron* necessitou de um pré-processamento a fim de viabilizar o treinamento.

A capacidade de generalização da rede neural profunda nos permite treinar a rede com espectros obtidos nas mais diversas condições, de modo que o modelo seja independente das condições de leitura, melhorando a qualidade do processo de caracterização.

5. AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, agradecemos também ao Instituto de Pesquisas Energéticas e Nucleares, IPEN-CNEN/SP, pelo auxílio na utilização das instalações e equipamentos utilizados neste trabalho.

REFERÊNCIAS

- [1] INTERNATIONAL ATOMIC ENERGY AGENCY - IAEA. **Radioactive waste management glossary**, Vienna, 2003.
- [2] McCulloch, Warren S., and Walter Pitts. "A logical calculus of the ideas immanent in nervous activity." *The bulletin of mathematical biophysics* 5.4 (1943): 115-133.
- [3] Rosenblatt, Frank. "The perceptron: A probabilistic model for information storage and organization in the brain." *Psychological review* 65.6 (1958): 386.
- [4] Cireşan, Dan, et al. "Deep neural networks segment neuronal membranes in electron microscopy images." *Advances in neural information processing systems*. 2012.
- [5] Cireşan, Dan, Ueli Meier, and Jürgen Schmidhuber. "Multi-column deep neural networks for image classification." *Computer Vision and Pattern Recognition (CVPR), 2012 IEEE Conference on*. IEEE, 2012.
- [6] Hinton, Geoffrey, et al. "Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups." *IEEE Signal Processing Magazine* 29.6 (2012): 82-97.
- [7] Wu, Yonghui, et al. "Google's Neural Machine Translation System: Bridging the Gap between Human and Machine Translation." *arXiv preprint arXiv:1609.08144* (2016).
- [8] Zhang, Richard, Phillip Isola, and Alexei A. Efros. "Colorful image colorization." *European Conference on Computer Vision*. Springer International Publishing, 2016.
- [9] Krizhevsky, Alex, Ilya Sutskever, and Geoffrey E. Hinton. "Imagenet classification with deep convolutional neural networks." *Advances in neural information processing systems*. 2012.

- [10] KELLER, Paul E. et al. Nuclear spectral analysis via artificial neural networks for waste handling. *IEEE transactions on nuclear science*, v. 42, n. 4, p. 709-715, 1995.
- [11] VIGNERON, Vincent et al. **Statistical modelling of neural networks in γ -spectrometry.** *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, v. 369, n. 2-3, p. 642-647, 1996.
- [12] YOSHIDA, Eiji et al. **Application of neural networks for the analysis of gamma-ray spectra measured with a Ge spectrometer.** *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, v. 484, n. 1, p. 557-563, 2002.
- [13] POTIENS, Junior; ADEMAR, Jose. **Artificial neural network application in isotopic characterization of radioactive waste drums.** 2005.
- [14] LeCun, Yann, Yoshua Bengio, and Geoffrey Hinton. **"Deep learning."** *Nature* 521.7553 (2015): 436-444.
- [15] SIMONYAN, Karen; ZISSERMAN, Andrew. **Very deep convolutional networks for large-scale image recognition.** *arXiv preprint arXiv:1409.1556*, 2014.
- [16] BUITINCK, Lars et al. API design for machine learning software: experiences from the scikit-learn project. In: **European Conference on Machine Learning and Principles and Practices of Knowledge Discovery in Databases.** 2013.
- [17] CHOLLET, François et al. **Keras.** 2015.