



## **UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL NA IDENTIFICAÇÃO DE MINERAIS RADIOATIVOS**

Daniel B. A. Couto

[danielbraga936@gmail.com](mailto:danielbraga936@gmail.com)

Diogo A. Reis

[di.diogo.3103@gmail.com](mailto:di.diogo.3103@gmail.com)

Guilherme A. S. Elias

[guilherme.ase2@gmail.com](mailto:guilherme.ase2@gmail.com)

Igor M. Alves

[igor.dominus04@gmail.com](mailto:igor.dominus04@gmail.com)

Pedro Wan D. M. Santos

[pedrowan.dms@gmail.com](mailto:pedrowan.dms@gmail.com)

Yasmim V. S. Pereira

[yasmimvitoriasp@hotmail.com](mailto:yasmimvitoriasp@hotmail.com)

Edyene Oliveira

[edyene.oliveira@prof.una.br](mailto:edyene.oliveira@prof.una.br)

Centro Universitário UNA<sup>1</sup> Av. Gov. Valadares, 640 - Centro, Betim, 32510-010, Minas Gerais, Brasil.

**Palavras-Chave** Ciência de Dados, Inteligência artificial, Minerais, Radiação, Rochas.

### **RESUMO**

Os minerais estão distribuídos ao redor da terra, na água no solo e nas plantas, também compõem grande parte do que é utilizado na sociedade como, recursos minerais energéticos, na construção civil, fertilizantes, panela, entre outros. Dentre os minerais alguns são radioativos e a identificação deles é realizada utilizando vários métodos, sendo o mais comum o contador Geiger-Müller. A proposta deste trabalho foi analisar a viabilidade da utilização de outro método para reconhecimento de minerais radioativos. Portanto, foi implementada uma ferramenta que utiliza inteligência artificial como meio de identificação de minerais radioativos usando visão computacional. Os testes realizados utilizaram 53 mil imagens, porém, em momentos diferentes. O objetivo deste método foi identificar a quantidade de imagens ideal para reconhecimento do modelo. Em vista disso, os testes começaram com cerca de 10 mil imagens, passando por 4 mil, 10 mil e finalizaram com 53.932 imagens. Tais imagens foram distribuídos em 9 classes, sendo: Autunita, Carnotita, Monazita, Amanita, Diamante, Ouro, Thorita, Torbernita e Uraninita. Os resultados mostraram que existe possibilidade de utilizar visão computacional para esta finalidade, pois, em alguns testes o modelo alcançou 80% de identificação das imagens destes minerais.

## **1. INTRODUÇÃO**



Os minerais estão presentes no nosso cotidiano bem mais do que podemos imaginar, desde a pasta dental até os materiais de construção. Apesar da mineralogia ser utilizada como ciência ser recente, sua prática aplicada à arte é tão antiga quanto a civilização humana [1].

Dentre os minerais existentes alguns são radioativos. Segundo [2], além dos núclídeos estáveis, existem os instáveis, que são radioativos, denominados radioisótopos ou radionuclídeos. Como a maioria das rochas, solos, sedimentos e minérios contêm concentrações significativas de urânio e tório, como consequência dos decaimentos, estes materiais contêm também os radionuclídeos pertencentes às famílias radioativas. Como o radônio e o torônio são gasosos, nos ambientes construídos por materiais como, cerâmica, revestimento de pedra, granito, argamassa, concreto, gesso, vai ocorrer o fenômeno da emissão destes gases radioativos. Como eles possuem um peso atômico elevado, sua concentração é maior em níveis próximos do solo, devido à decantação gravitacional. Assim, juntamente com os gases componentes do ar, o homem e os animais respiram gases e aerossóis radioativos.

O método mais comumente utilizado para identificar radioatividade são os detectores Geiger-Müller. Eles foram introduzidos em 1928 e, em função de sua simplicidade, baixo custo, facilidade de operação e manutenção, são utilizados até hoje [2].

Dito isso, este trabalho tem como objetivo realizar um estudo a fim de verificar a possibilidade de utilizar visão computacional para identificar minerais radioativos. A proposta é gerar um modelo de redes neurais artificiais (RNA) a fim de reconhecer visualmente alguns tipos de rochas radioativas [3].

Para este processo foi implementado um modelo de redes neurais artificiais, pois, elas possuem capacidade de generalizar, sendo assim, é o modelo adequado para esta proposta [4]. As redes neurais fazem parte de um subconjunto da Inteligência Artificial (AI) e por meio de Visão Computacional elas conseguem associar uma imagem a um rótulo. Assim, o plano foi verificar se um modelo de RNA pode identificar um mineral radioativo por meio de visão computacional.

## 1.1 Citação de Referências

Nesta linha de pesquisa não foram encontrados muitos trabalhos, porém, pode ser citado o trabalho de [5]. Neste trabalho os autores organizaram uma plataforma com dados dos minerais radioativos encontrados na natureza.

O IRD (Instituto de Radioproteção de Dosimetria) mantém uma base de dados com informações sobre locais, no Brasil com certa quantidade de radioatividade <sup>1</sup>. O Georad é o banco de dados que fornece dados sobre radioatividade ambiental, proveniente de pesquisas e de registros na literatura científica. A partir de um formulário o usuário pode escolher a região, cidade, compartimento, tipo de amostra e ano de publicação. A base de dados permite geração de informações em planilha.

Além do banco de dados Georad existe também outra base de dados mantida pelo IRD, é o Maprad. O objetivo deste projeto é mapear a radioatividade no solo brasileiro e de disponibilizar

---

<sup>1</sup> GEORAD ([ird.gov.br](http://ird.gov.br))



para os tomadores de decisão, comunidade científica e público em geral dados sobre a radioatividade no solo brasileiro <sup>2</sup>.

O trabalho de [6] teve como objetivo caracterizar os minerais pesados presentes nos sedimentos praias, bem como avaliar o risco ambiental promovido pela radioatividade natural destes sedimentos.

Plataformas e bases de dados foram encontrados, porém, não foram encontrados estudos sobre identificação de minerais radioativos usando outros métodos, que não sejam os convencionais.

## 2. METODOLOGIA

O projeto teve início com geração da base de dados com as imagens para treinamento do modelo de inteligência artificial. O modelo utilizado foi uma rede neural artificial.

A base de dados de imagens foi gerada a partir do site Mindat.org<sup>3</sup>. Este site é o maior banco de dados aberto do mundo de minerais, rochas, meteoritos e inclui sua localização. A obtenção das imagens teve início com um projeto disponível no GitHub<sup>4</sup> e um arquivo em Excel que incluiu 624.837 links de imagens do site.

Para esta etapa, fez-se necessário o desenvolvimento de um programa para efetuar o download. Este foi codificado na linguagem Python e os dados recebidos foram gravados em um arquivo no formato .csv (*Coma Separated Values*).

Ao final o arquivo dispunha de 624.837 imagens de minerais no geral, dessas cerca de 5.000 imagens eram de minerais radioativos gerados naturalmente, como: Autunite, Carnotite, Monazite, Thorite, Torbernite, Uraninite.

Após a extração dos dados, estes foram enviados para pré-processamento. Esta etapa consiste em minerar os dados eliminando redundâncias, dados incompatíveis, limpeza e organização.

Em seguida, foi utilizado a ferramenta Orange Canvas Data Mining<sup>5</sup>. Este software disponibiliza ferramentas de visualização de dados, aprendizado de máquina e mineração de dados que pode ser utilizado para trabalhos com inteligência artificial. Nesta etapa, as imagens foram submetidas a cálculos matemáticos para o encontro de padrões e obtenção de resultados.

Os testes foram realizados usando o método de Cross Validation, que é uma técnica para avaliar a capacidade de generalização de um modelo, a partir de um conjunto de dados. As técnicas de redes neurais artificiais apresentam modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. Também foi utilizada a função de ativação ReLu e o otimizador aplicado foi o Adam. Foram utilizadas 54 mil imagens de minerais para treinamento do modelo de rede neural. Esta quantidade foi dividida em 9 classes, são elas: Autunite, Carnotite, Monazite, Amanite, Diamante, Ouro, Thorite, Torbernite e Uraninite.

---

<sup>2</sup> Estudo sobre radioatividade em solos brasileiros reúne IRD e CPRM — Instituto de Radioproteção e Dosimetria - IRD ([www.gov.br](http://www.gov.br))

<sup>3</sup> <https://www.mindat.org>

<sup>4</sup> <https://github.com>

<sup>5</sup> <https://orangedatamining.com>



Com objetivo de gerar maior quantidade de imagens para treinamento do modelo de redes neurais, foi utilizada a técnica de *Data Augmentation*. Esta técnica tem como objetivo gerar novas imagens a partir das originais sem perda de qualidade. É indicada para casos em que a quantidade de imagens não é suficiente para treinamento do modelo. Afinal, quanto mais dados melhor para obtenção de um modelo eficiente. Neste trabalho, a técnica de *Data Augmentation* foi feita multiplicando 1 imagem em 5 novas diferentes a partir de um código desenvolvido em Python.

Para que as imagens fossem apresentadas para o modelo embaralhadas, foi necessário utilizar um algoritmo para esta finalidade, o SqueezeNet. Desta forma, para validação do modelo foram utilizadas (20%) do total de imagens distribuídas entre todas as 9 opções de minerais iniciais. As Fig. 1 até a Fig.6 mostram exemplos de imagens de minerais usados para treinamento da rede neural artificial.



Fig. 1 - Uraninite

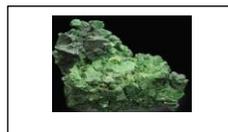


Fig. 2 - Torbernite



Fig. 3 - Thorite



Fig. 4 - Monazite

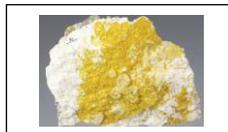


Fig. 5 - Carnotite



Fig. 6 - Autunite

### 3. RESULTADOS

A proposta do artigo foi a criação de um modelo de redes neurais para verificar a possibilidade de reconhecimento de minerais radioativos. As imagens foram apresentadas ao modelo e o objetivo era que ele pudesse identificar e informar o nome do mineral.

As imagens abaixo mostram a matriz de confusão dos testes realizados. Como pode ser observado, foram realizados 6 casos de testes com quantidade de imagens variadas. O objetivo foi identificar a quantidade ideal para alcançar maior assertividade por parte do modelo.

Na Fig.7 pode ser visto um resultado do treinamento da rede neural. A figura apresenta uma matriz de confusão que é uma tabela que permite a visualização do desempenho de um modelo classificatório. Ela apresenta de forma detalhada o resultado da classificação, comparando as previsões do modelo com os valores reais dos dados, mostrando percentualmente os acertos e erros. Foram utilizadas 9.897 imagens.



		Predicted									
		Autunite	Carnotite	Monazite	NR - Adamite	NR - Diamond	NR - Gold	Thorite	Torbernite	Uraninite	Σ
Actual	Autunite	61.1 %	0.6 %	3.5 %	8.4 %	0.2 %	9.8 %	0.5 %	12.8 %	2.9 %	959
	Carnotite	12.2 %	26.8 %	4.9 %	10.6 %	0.8 %	28.5 %	2.4 %	4.1 %	9.8 %	123
	Monazite	3.6 %	0.4 %	65.7 %	4.8 %	2.0 %	12.3 %	4.7 %	2.1 %	4.4 %	954
	NR - Adamite	4.2 %	0.5 %	3.3 %	77.4 %	0.9 %	5.4 %	0.5 %	7.3 %	0.6 %	1524
	NR - Diamond	0.9 %	0.0 %	2.2 %	1.6 %	82.8 %	8.3 %	0.7 %	0.4 %	3.2 %	697
	NR - Gold	1.6 %	0.2 %	3.2 %	2.0 %	1.1 %	88.8 %	0.5 %	1.1 %	1.5 %	3458
	Thorite	4.1 %	0.7 %	21.5 %	5.6 %	3.0 %	11.9 %	37.8 %	4.8 %	10.7 %	270
	Torbernite	8.1 %	0.2 %	1.7 %	5.5 %	0.5 %	4.2 %	0.6 %	77.3 %	2.0 %	1271
	Uraninite	3.9 %	0.6 %	5.5 %	2.0 %	2.8 %	13.6 %	4.2 %	5.0 %	62.4 %	641
Σ		899	66	956	1497	684	3629	220	1327	619	9897

Fig. 7. Matriz de confusão com 9 minerais e 9.897 imagens.

Na Fig. 8 pode ser visualizado o resultado obtido com o uso de 500 imagens por mineral, como um teste de aprendizado e foi retirado o diamante dos testes.

		Predicted								
		Adamite NR	Autunite	Carnotite	Gold NR	Monazite	Thorite	Torbernite	Uraninite	Σ
Actual	Adamite NR	73.5 %	6.4 %	0.9 %	4.6 %	5.0 %	0.6 %	6.4 %	2.6 %	544
	Autunite	7.5 %	64.9 %	5.0 %	2.4 %	3.6 %	1.8 %	10.5 %	4.2 %	496
	Carnotite	1.1 %	4.5 %	82.7 %	0.6 %	2.6 %	2.2 %	1.1 %	5.2 %	463
	Gold NR	3.5 %	2.5 %	2.8 %	78.9 %	4.9 %	1.8 %	1.6 %	3.9 %	608
	Monazite	4.6 %	3.6 %	2.6 %	5.8 %	64.7 %	7.9 %	2.8 %	7.9 %	496
	Thorite	3.0 %	2.1 %	3.7 %	4.0 %	14.9 %	49.7 %	5.5 %	17.1 %	328
	Torbernite	9.0 %	9.0 %	1.8 %	2.7 %	2.1 %	2.1 %	69.7 %	3.5 %	512
	Uraninite	1.4 %	3.9 %	4.5 %	2.5 %	5.8 %	6.9 %	2.7 %	72.4 %	641
Σ		551	489	493	592	505	290	508	660	4088

Fig. 8. Matriz de confusão com 8 minerais e 4.088 imagens.

Na Fig. 8 percebeu-se que havia uma taxa de verdadeiros positivos elevada em relação aos testes anteriores.

Para o teste seguinte da Fig.9 mais imagens foram acrescentadas ao dataset. Estas foram extraídas de buscas no navegador Bing<sup>6</sup>, a fim de melhorar o modelo de Machine Learning, totalizando 10.269 imagens. Além disso, o Diamante foi incluído neste teste.

<sup>6</sup> <https://br.bing.com>



		Predicted									
		Adamite NR	Autunite	Carnotite	Diamond NR	Gold NR	Monazite	Thorite	Torbernite	Uraninite	Σ
Actual	Adamite NR	80.5 %	3.3 %	0.7 %	0.5 %	5.1 %	2.5 %	1.1 %	6.0 %	0.5 %	1523
	Autunite	7.4 %	60.8 %	3.4 %	0.3 %	7.9 %	2.8 %	0.6 %	14.7 %	2.0 %	959
	Carnotite	1.5 %	4.8 %	79.3 %	0.2 %	6.3 %	2.4 %	0.4 %	1.9 %	3.2 %	463
	Diamond NR	1.7 %	1.0 %	0.6 %	83.4 %	8.2 %	1.1 %	1.0 %	0.6 %	2.4 %	697
	Gold NR	1.6 %	1.0 %	0.8 %	1.2 %	90.2 %	2.4 %	0.3 %	1.0 %	1.6 %	3458
	Monazite	4.4 %	2.9 %	1.5 %	2.3 %	11.6 %	65.8 %	3.5 %	3.1 %	4.8 %	954
	Thorite	6.6 %	2.6 %	2.3 %	1.3 %	11.6 %	15.8 %	41.3 %	4.0 %	14.5 %	303
	Torbernite	5.5 %	6.7 %	0.8 %	0.4 %	3.6 %	1.7 %	0.6 %	79.3 %	1.3 %	1271
	Uraninite	2.3 %	4.2 %	3.1 %	3.0 %	10.6 %	7.0 %	4.1 %	3.0 %	62.7 %	641
Σ		1518	845	491	682	3617	910	235	1350	621	10269

Fig. 9. Matriz de confusão com 9 minerais e 10.269 imagens.

O resultado Fig.10 se manteve distante de números ideais de 80% de verdadeiros positivos em alguns minerais importantes, como Autunite, Monazita, Thorita e Uraninite. Por isso, foi adotada a técnica de *Data Augmentation* que tem como objetivo melhorar a qualidade dos dados e conseqüentemente o desempenho dos modelos de aprendizado. A técnica consiste no processamento de imagens e expansão do banco de imagens de treinamento disponíveis, através da criação de novas amostras a partir das já existentes.

		Predicted									
		Adamite NR	Autunite	Carnotite	Diamond NR	Gold NR	Monazite	Thorite	Torbernite	Uraninite	Σ
Actual	Adamite NR	63.3 %	8.3 %	0.6 %	0.7 %	10.4 %	7.6 %	1.0 %	5.3 %	2.9 %	1523
	Autunite	1.4 %	79.4 %	0.8 %	0.1 %	2.5 %	7.7 %	1.2 %	2.1 %	4.8 %	5754
	Carnotite	1.5 %	11.9 %	71.7 %	0.4 %	4.8 %	1.5 %	1.1 %	0.9 %	6.3 %	463
	Diamond NR	1.6 %	3.6 %	0.1 %	67.4 %	9.5 %	7.6 %	2.4 %	0.4 %	7.3 %	697
	Gold NR	3.2 %	3.6 %	0.6 %	1.6 %	79.0 %	6.0 %	1.3 %	0.5 %	4.3 %	3458
	Monazite	1.3 %	8.7 %	0.3 %	0.5 %	3.6 %	73.6 %	3.9 %	0.3 %	7.8 %	5724
	Thorite	0.6 %	9.1 %	0.1 %	0.4 %	3.1 %	22.3 %	48.8 %	0.9 %	14.7 %	1568
	Torbernite	5.6 %	14.5 %	0.5 %	0.2 %	3.1 %	2.5 %	1.6 %	70.0 %	2.1 %	1271
	Uraninite	0.9 %	7.7 %	0.7 %	0.6 %	2.7 %	13.3 %	3.4 %	0.8 %	69.8 %	3846
Σ		1358	6020	457	604	3522	5930	1292	1181	3940	24304

Fig. 10. Matriz de confusão com 9 minerais e 24.304 imagens

Ao se utilizar a técnica de *Data Augmentation* nos minerais com menor porcentagem de verdadeiros positivos, foi observado um aumento nas porcentagens de verdadeiros positivos em relação a Autunite, que anteriormente apresentava um percentual de 60.8% e agora teve 79,4%. A Monazita apresentava um percentual de 65,8% e agora 73,6%. A Thorita seguiu com um percentual médio menor que a maioria ao utilizar a técnica com um aumento percentual de 41,3% para 48,8%. A Uraninite anteriormente apresentava 62,7% e agora 69,8%.

Para os testes apresentados na Fig. 11, foi utilizada novamente a técnica de *Data Augmentation* transformando 1 imagem em 5 novas diferentes. Foram utilizadas 25.542 imagens distribuídas entre todos os 6 minerais radioativos naturais.



		Predicted						
		Autunite	Carnotite	Monazite	Thorite	Torbernite	Uraninite	Σ
Actual	Autunite	70.2 %	3.8 %	7.4 %	1.0 %	13.8 %	3.8 %	5754
	Carnotite	13.2 %	62.1 %	9.5 %	1.8 %	5.6 %	7.8 %	2295
	Monazite	6.1 %	3.1 %	74.8 %	3.7 %	5.2 %	7.1 %	5724
	Thorite	6.1 %	4.0 %	21.2 %	47.6 %	7.8 %	13.4 %	1568
	Torbernite	10.5 %	2.2 %	4.5 %	1.0 %	77.8 %	3.9 %	6355
	Uraninite	6.0 %	4.8 %	11.7 %	3.7 %	6.7 %	67.2 %	3846
Σ		5685	2209	5993	1261	6549	3845	25542

Fig. 11. Matriz de confusão com 6 minerais e 25.542 imagens.

O resultado da Fig. 11 ainda não atende a porcentagem de 80% de verdadeiros positivos, Apenas Torbernita apresentou um aumento no percentual.

Por este motivo, foi realizado mais um teste que pode ser visualizado na Fig. 12. Neste teste foi utilizada a técnica em todos os minerais, sejam radioativos ou não. Para esse último teste, foi utilizado um banco de 53.932 imagens.

		Predicted									
		Adamite NR	Autunite	Carnotite	Diamond NR	Gold NR	Monazite	Thorite	Torbernite	Uraninite	Σ
Actual	Adamite NR	56.9 %	5.4 %	0.8 %	1.2 %	20.0 %	5.2 %	0.3 %	7.8 %	2.3 %	7615
	Autunite	8.6 %	57.5 %	3.1 %	0.7 %	14.7 %	3.2 %	0.5 %	9.8 %	1.7 %	5754
	Carnotite	5.5 %	8.1 %	50.6 %	1.2 %	22.9 %	3.7 %	0.3 %	3.4 %	4.2 %	2295
	Diamond NR	4.1 %	1.8 %	0.9 %	64.8 %	16.4 %	5.0 %	0.8 %	2.4 %	3.8 %	3485
	Gold NR	5.4 %	2.5 %	1.5 %	2.3 %	79.3 %	4.1 %	0.4 %	2.1 %	2.4 %	17290
	Monazite	6.7 %	2.8 %	1.2 %	2.5 %	21.7 %	55.5 %	2.3 %	2.5 %	4.8 %	5724
	Thorite	5.0 %	3.3 %	1.5 %	4.0 %	19.9 %	18.4 %	32.3 %	5.0 %	10.7 %	1568
	Torbernite	7.8 %	8.8 %	1.4 %	0.7 %	9.6 %	2.2 %	0.3 %	66.9 %	2.3 %	6355
	Uraninite	5.4 %	3.0 %	3.0 %	3.1 %	20.8 %	7.1 %	1.7 %	3.5 %	52.4 %	3846
Σ		7194	5296	1981	3194	20151	5423	888	6287	3518	53932

Fig. 12. Matriz de confusão com 9 minerais e 53.932 imagens.

O resultado Fig.12 obteve o efeito contrário do esperado, com o decaimento do percentual de verdadeiros positivos em relação ao teste com somente os minerais com o percentual menor.

#### 4. CONCLUSÃO

Este trabalho teve como objetivo realizar análise da possibilidade de reconhecer minerais radioativos por meio de visão computacional.



Neste trabalho, 624.837 imagens foram obtidas e destas 5.000 eram radioativas. As imagens foram armazenadas em uma base de dados. Com este banco de dados próprio o objetivo foi apresentar cada imagem para o modelo e por meio de visão computacional realizar identificação. A longo prazo pretende-se obter quantidade maior de imagens a fim de treinar o modelo e verificar se é possível diferenciar um material radioativo dentre outros minerais.

O estudo mostrou que é necessário maior quantidade de imagens sendo ou não radioativas. A quantidade auxilia o modelo a reconhecer e diferenciar os minerais. Percebeu-se que será necessário também realizar técnicas de tratamento de imagens a fim de implementar qualidade e auxiliar o modelo de inteligência artificial.

Mesmo com quantidade pequena de imagens o estudo mostrou que pode ser possível identificar minerais radioativos. Importante ressaltar que o objetivo do processo não é substituir, mas, sim, auxiliar os métodos de reconhecimento de radioatividade existentes. Nos testes realizados o modelo alcançou 80% de acertos positivos em todos os minerais avaliados.

## AGRADECIMENTOS

Agradecimentos a professora Edyene por todo o apoio prestado e orientações, agradecimentos também a UFMG pela oportunidade.

## REFERÊNCIAS BIBLIOGRÁFICAS

- [1] B. D. C. Klein, *Manual de Ciência dos Minerais*, 23rd ed. 2001.
- [2] A. R. Tauhata, Luiz; Salati, Ivan P. A; Di Prinzio, Renato; Di Prinzio, *Radiação Ionizante / Proteção Radiológica / Poluentes Radioativos / Radioatividade / Radioterapia / Dosimetria*. 1999.
- [3] P. Norvig and S. Russell, *Inteligência artificial: Tradução da 3a Edição*. Elsevier Brasil, 2014. [Online]. Available: <https://books.google.com.br/books?id=BsNeAwAAQBAJ>
- [4] S. Haykin, “Redes neurais: princípios e prática,” *Bookman*, 2017, doi: 8573077182.
- [5] E. O. Laisa Frois, Izabella Quaresma, Bruno Micael, Camila Mariano, “IMPLEMENTAÇÃO DE PLATAFORMA DE DADOS SOBRE MINERAIS RADIOATIVOS UTILIZANDO CIÊNCIA DE DADOS,” 2018.
- [6] P. P. de França, “Caracterização de minerais pesados e avaliação da radioatividade natural ‘IN SITU’ em sedimentos praias de Acaú, Carne de Vaca e Ponta de Pedras do Estuário do Rio Goiana,” 2013, [Online]. Available: <https://repositorio.ufpe.br/handle/123456789/10460>



**Semana Nacional de Engenharia Nuclear e da Energia e Ciências das Radiações – VII SENCIR**  
Belo Horizonte, 12 a 14 de novembro de 2024