

Utilização de algoritmos de *Machine Learning* na predição de dose radiológica em radiografias de tórax em PA: uma ferramenta de apoio à física médica

Application of machine learning algorithms for radiological dose prediction in PA chest radiographs: a support tool for medical physics

Gustavo O. Conceição¹, César M. Salgado², Roberto Schirru³

^{1,3}Programa de Engenharia Nuclear - COPPE-UFRJ, Cidade Universitária, RJ, Brasil.

²Instituto de Engenharia Nuclear - SEDTN, Cidade Universitária, RJ, Brasil.

Resumo

A predição da Dose de Entrada na Pele (DEP) é essencial para garantir a qualidade e a segurança em exames de radiografia de tórax. Este estudo investigou a aplicação de algoritmos de machine learning na estimativa da DEP a partir de fatores técnicos, como, mAs, kV, distância foco-filme e espessura do paciente. Foram analisados dados de 150 radiografias de tórax com estimativa de dose baseada em cálculo físico. Modelos de aprendizado supervisionado, incluindo Rede Neural Artificial (RNA) e Random Forest Regressor (RFR), foram treinados e avaliados quanto ao desempenho preditivo. A RNA apresentou erro absoluto médio (Mean Absolute Error – MAE) de 0,008 mGy e coeficiente de determinação $R^2 = 0,991$, enquanto o RFR obteve MAE de 0,022 mGy e $R^2 = 0,765$. A média da DEP foi de $0,284 \pm 0,117$ mGy, enquanto o conjunto de teste apresentou média de $0,268 \pm 0,121$ mGy. As médias preditas foram de $0,285 \pm 0,010$ mGy pela RNA e $0,275 \pm 0,030$ mGy pelo RFR. Os resultados indicam que a RNA apresentou menor erro preditivo e maior coeficiente de determinação em relação ao RFR. Esses resultados reforçam o potencial de algoritmos de machine learning como ferramenta de apoio à radioproteção e à otimização de parâmetros técnicos em ambientes clínicos.

Palavras-chave: Dose de Entrada na Pele; Radiografia de Tórax; Aprendizado de máquina; Radioproteção; Física Médica.

Abstract

The prediction of Entrance Skin Dose (ESD) is essential to ensure quality and safety in chest radiography examinations. This study investigated the application of machine learning algorithms to estimate ESD based on technical factors such as mAs, kV, focus-to-film distance, and patient thickness. Data from 150 chest radiographs with dose estimated by physical calculation were analyzed. Supervised learning models, including Artificial Neural Network (ANN) and Random Forest Regressor (RFR), were trained and evaluated for predictive performance. The ANN achieved a mean absolute error (MAE) of 0.008 mGy and a coefficient of determination $R^2 = 0.991$, while the RFR obtained an MAE of 0.022 mGy and $R^2 = 0.765$. The mean ESD was 0.284 ± 0.117 mGy, while the test set presented a mean of 0.268 ± 0.121 mGy. The predicted means were 0.285 ± 0.010 mGy for the ANN and 0.275 ± 0.030 mGy for the RFR. The results indicate that the ANN achieved lower prediction error and higher coefficient of determination compared to the RFR. These findings highlight the potential of machine learning as a supportive tool for radiation protection and the optimization of technical parameters in clinical environments.

Keywords: Entrance Skin Dose; Chest Radiography; machine learning; Radiation Protection; Medical Physics.

1. Introdução

A radiografia de tórax é um dos exames de imagem mais frequentemente realizados na prática clínica, devido à sua ampla disponibilidade, baixo custo e rapidez na obtenção dos resultados. Embora envolva doses relativamente baixas de radiação ionizante, a elevada frequência com que é solicitada torna imprescindível a adoção de medidas rigorosas de proteção radiológica (1,2).

De acordo com a Agência Internacional de Energia Atômica (IAEA, 2014) (3), a otimização da dose em exames radiológicos é um princípio essencial, sobretudo em procedimentos de alta demanda, como a radiografia de tórax na projeção pósterio-anterior (PA). O objetivo é assegurar que a exposição do paciente seja tão baixa quanto razoavelmente exequível, sem comprometer a qualidade diagnóstica. A dose de radiação absorvida

pelos pacientes em exames radiológicos é um dos principais pontos de atenção na radiologia diagnóstica. Em particular, a Dose de Entrada na Pele (DEP) é frequentemente utilizada como parâmetro de referência para avaliar e monitorar a exposição do paciente durante radiografias de tórax (4). O conceito de Níveis de Referência de Diagnóstico (NRD) foi introduzido pela Comissão Internacional de Proteção Radiológica (ICRP) na década de 1990, definido como os níveis de dose de entrada do paciente para exames típicos realizados em pacientes ou *Phantoms* de referência (5). No Brasil, a Instrução Normativa (IN) nº 90/21 da ANVISA (6) estabelece NRDs para alguns procedimentos em termos DEP. Para radiografias de tórax em PA em adultos típicos (60–75 kg e 1,60–1,75 m), o NRD é de aproximadamente 0,4 mGy de DEP.

Além disso, a RDC 611/22 exige a implantação de um Programa de Garantia de Qualidade (7). Com

o advento das novas tecnologias e a crescente demanda pelo uso de algoritmos de *machine learning* em aplicações de imagem médica, este estudo propõe a utilização desses métodos para a predição da Dose de Entrada na Pele (DEP) em exames de radiografia de tórax em PA. Segundo Haykin *et al.* (2009) (8), o aprendizado profundo (*deep learning*) é uma subárea do aprendizado de máquina (*machine learning*) que emprega algoritmos inspirados no funcionamento do cérebro humano. Esse processo é simulado por um conjunto de neurônios artificiais organizados em camadas, de modo que cada unidade processa informações e transmite o resultado à camada seguinte. A Figura 1 ilustra a analogia entre o funcionamento de um neurônio biológico e de um neurônio artificial. No neurônio biológico, os estímulos chegam pelos dendritos, são processados no corpo celular e propagados ao longo do axônio até os terminais. No neurônio artificial, as entradas (in) representam os fatores de entrada do modelo, que são multiplicados por pesos, somados (Σ) e ajustados pelo termo bias. Esse valor passa por uma função de ativação (f), que define se o neurônio “dispara” ou não, gerando uma saída (out). Essa saída é então transmitida para a camada seguinte, permitindo que a rede aprenda padrões complexos.




Figura 1. Comparação entre um neurônio biológico e um neurônio artificial. Fonte: Quora, adaptado pelo autor (2026)

Em um estudo prévio para estimativas precisas da DEP em radiografias de tórax, Abdo *et al.* (2011) (9) avaliaram doses absorvidas em órgãos em exames típicos de tórax, utilizando fantoma antropomórfico *Rando-Alderson* e dosímetros termoluminescentes. Os resultados foram comparados a cálculos obtidos pelos softwares de Monte Carlo PCXMC® e CALDose_X, evidenciando diferenças associadas às limitações anatômicas dos modelos virtuais (9). Essas simulações, baseadas em fantasmas virtuais e *softwares* como o PCXMC (*Patient Dose Calculation in Medical X-ray Examinations*) têm apresentado valores consistentes com medições físicas por dosímetros, configurando-se como padrão-ouro para validação de métodos alternativos, incluindo aqueles baseados em aprendizado de máquina.

Diferentemente desses estudos, que dependem de modelagem física detalhada via Monte Carlo, o

presente trabalho propõe uma alternativa baseada em aprendizado de máquina, treinada com dados reais de exames. Yu *et al.* (2019) (10) demonstraram o potencial dos algoritmos de aprendizado de máquina na predição de dose absorvida em exames de imagem médica, ao desenvolverem um modelo automatizado baseado em redes neurais convolucionais (*Convolutional Neural Networks – CNNs*) para estimar a dose fetal em gestantes submetidas à tomografia computadorizada, alcançando alta precisão na segmentação anatômica e nas simulações de dose via Monte Carlo.

Outros autores também exploraram aplicações de *machine learning* em radiografias de tórax Lin *et al.* (2025) (11), desenvolveram um modelo de aprendizado de máquina para prever valores apropriados de mAs a partir de variáveis como espessura torácica, altura e peso, demonstrando a possibilidade de otimizar a exposição sem comprometer a qualidade da imagem. Mori *et al.* (2025) (12), por sua vez, aplicaram redes neurais profundas para redução de ruído em imagens de tórax, permitindo a diminuição da dose administrada sem perda diagnóstica significativa. Apesar da relevância, ambos os trabalhos abordam a dose de forma indireta, diferentemente do presente estudo, que busca a predição direta da DEP em radiografias de tórax PA.

Nesse contexto, é importante destacar que algoritmos de aprendizado de máquina, como o *Random Forest*, já têm sido aplicados em outras áreas da radiologia relacionadas à dose, incluindo a classificação de exposições seguras a raios X (13) a predição de dose efetiva em tomografias computadorizadas (14) e a estimativa de distribuição de dose em planejamentos de radioterapia IMRT (*Intensity-Modulated Radiation Therapy*) (15). Considerando esse cenário, o presente estudo aplica os modelos *Random Forest* e Rede Neural Artificial para estimar a DEP em radiografias de tórax em PA utilizando como variáveis de entrada os fatores radiográficos dos pacientes.

2. Materiais e Métodos

Os dados foram anonimizados e coletados conforme os princípios éticos, em projeto aprovado pelo Comitê de Ética em Pesquisa (parecer consubstanciado nº 4.885.555). Foram analisados 150 exames de radiografia de tórax em PA de pacientes adultos, realizados no Hospital Federal de Bonsucesso (RJ). As informações foram extraídas de planilhas organizadas por plantões. Os parâmetros técnicos (kV, mAs e distância foco-filme (DFF)) foram obtidos diretamente do equipamento radiográfico no momento da realização dos exames. A espessura torácica dos pacientes foi mensurada durante o procedimento radiográfico. A dose de entrada na pele (DEP), foi estimada por meio de cálculo baseado no Kerma no ar e na aplicação do fator de retroespalhamento, descrito nas equações apresentadas abaixo. Ressalta-se que as imagens radiográficas não foram utilizadas como entrada nos

modelos de *machine learning*, sendo considerados exclusivamente os fatores técnicos como variáveis preditoras. Para a avaliação dos modelos, a amostra de 150 exames foi dividida em subconjuntos de treinamento, validação e teste. O conjunto de teste foi composto por 23 amostras, correspondendo a aproximadamente 15% da base total. As demais amostras foram subdivididas em 104 para treinamento e 23 para validação, correspondendo aproximadamente a 70% e 15% dos dados, respectivamente.

2.1 Cálculo da Dose de Entrada na Pele (DEP)

Nos exames de tórax em PA, os fatores radiográficos kV, mAs, DFF e espessura do tórax registrados em cada projeção foram utilizados para calcular o Kerma de entrada no ar (K_{air}). O rendimento do tubo (R) foi determinado a 100 cm do ponto focal para cada tensão aplicada. O K_{air} para cada projeção foi então calculado em função do mAs e da distância foco-paciente, conforme a Equação 1.

$$K_{air} = \frac{R \cdot mAs \cdot 100^2}{D_{FP}^2} \quad (1)$$

Em que:

K_{air} – Kerma de entrada no ar;

R – Rendimento do tubo (mGy/mAs);

mAs – produto entre a corrente do tubo (mA) e o tempo de exposição (s);

DFF – Distância foco-paciente (cm).

O valor de Kerma obtido foi multiplicado pelo fator de retroespalhamento (*Backscatter factor-BSF*) específico para a região torácica, resultando na DEP, conforme equação 2. De acordo com Wambersie (2005) (16), o BSF para tórax é de 1,4 (40%).

$$DEP = K_{air} \cdot BSF \quad (2)$$

Em que:

DEP – Dose de entrada na pele (mGy);

BSF – Fator de retroespalhamento.

2.2 Modelagem com Rede Neural

A Rede Neural Artificial (RNA) foi implementada com a classe MLP Regressor da biblioteca *scikit-learn*, utilizando como entradas as variáveis, mAs, kV, DFF e espessura torácica. O modelo (Figura 2) foi composto por duas camadas ocultas com 16 e 8 neurônios, função de ativação ReLU e camada de saída linear para predição da DEP. A função de perda adotada foi o erro quadrático médio (MSE), e o treinamento foi realizado com o algoritmo de otimização Adam (taxa de aprendizado de 0,001), ao longo de 200 épocas, utilizando *max_iter=1* e *warm_start=True* para monitoramento do erro nos conjuntos de treinamento e validação.




Figura 2. Arquitetura da Rede Neural Artificial (RNA).
Fonte: O autor (2026).

2.3 Modelagem Random Forest

O *Random Forest Regressor* (RFR) foi implementado com a biblioteca *scikit-learn*, usando 100 estimadores (árvores de decisão) com profundidade máxima automática. O modelo (Figura 3) foi treinado com os mesmos dados de entrada e avaliado nas mesmas proporções de treinamento, validação e teste utilizadas para a RNA. A predição da DEP foi avaliada pelas métricas MAE e coeficiente de determinação (R^2).




Figura 3. Arquitetura do Random Forest Regressor (RFR).
Fonte: O autor (2026).

A média das doses previstas foi calculada posteriormente a partir dos resultados dos modelos, não constituindo uma saída direta da RNA ou do RFR. As predições foram então comparadas com os valores reais da dose medida, por meio de análise gráfica e estatística, bem como o valor de referência estabelecido pela ANVISA (0,4 mGy) para exames de tórax em PA.

3. Resultados e Discussões

A média da Dose de Entrada na Pele (DEP) medida nos 150 exames de radiografia de tórax foi de $0,284 \pm 0,117$ mGy, onde o valor apresentado corresponde ao desvio padrão da amostra. Considerando o conjunto de teste (23 amostras), a média da dose física medida foi de $0,268 \pm 0,121$ mGy. Esses resultados reforçam a viabilidade do uso de algoritmos de aprendizado de máquina na estimativa automatizada de dose em exames radiográficos de tórax em PA. A Figura 4 apresenta a comparação entre as doses físicas medidas e as previstas pelos dois modelos no conjunto de teste.

Observa-se que o RFR (gráfico esquerdo) apresentou maior variabilidade, especialmente em relação ao modelo baseado em RNA. Já a RNA (gráfico direito) apresentou menor dispersão dos

pontos em torno da linha de identidade, indicando melhor ajuste em relação ao modelo Random Forest.




Figura 4. Correlação entre valores reais e preditos para a RNA (direita) e o RFR (esquerda).
Fonte: O autor (2026)

Na Figura 5 é apresentada a evolução da MAE ao longo das épocas de treinamento utilizando o algoritmo de otimização Adam. Essa análise permitiu visualizar a redução progressiva do erro tanto no treinamento quanto na validação, sem evidências visuais de sobreajuste. O comportamento observado pode estar associado ao tamanho limitado da base de dados.




Figura 5. Curvas de aprendizado da RNA utilizando o Adam.
Fonte: O autor (2026)

A Tabela 1 apresenta a comparação entre as médias de DEP preditas pelos modelos com a dose física medida. O RFR estimou uma média de 0,275 mGy, subestimando a dose física em -3,2%. A RNA previu 0,285 mGy, com variação de apenas +0,4% em relação ao valor físico medido. Para referência, foi considerada a dose de 0,4 mGy, estabelecida pela IN nº 90/2021 da ANVISA.

Tabela 1. Desempenho dos modelos e comparação com a dose física medida.

Modelo/ Métrica	MAE (mGy)	R ²	MSE (mGy ²)	Dose Predita (mGy)	Desvio da dose física (%)
Média física	—	—	—	0,284 ± 0,117	100%
RFR	0,022	0,765	0,0030	0,275 ± 0,030	-3,2%
RNA	0,008	0,991	0,0001	0,285 ± 0,010	+0,4%
Dose de referência (IN	—	—	—	0,400	—

Fonte: O autor (2026).

Os modelos de aprendizado de máquina apresentaram baixo erro preditivo (MAE) e bom coeficiente de determinação (R^2) na estimativa da DEP em radiografias de tórax em PA. A RNA apresentou desempenho superior (MAE = 0,008 mGy; R^2 = 0,991), evidenciando menor dispersão entre os valores preditos e medidos. O modelo RFR, embora viável (MAE = 0,022 mGy; R^2 = 0,765), demonstrou tendência à subestimação, sobretudo em doses elevadas, indicando desempenho inferior em relação à RNA. Embora ambos os algoritmos sejam viáveis para a predição da DEP, a RNA mostrou maior aderência aos valores reais. O R^2 , amplamente utilizado para avaliar a proporção da variabilidade explicada pelos modelos, reforça essa conclusão. De acordo com Chakraborty (2021) (17) em contextos médicos, valores entre 0,6 e 0,9 já são considerados satisfatórios quando associados a baixos erros de predição. Nota-se que a maioria das amostras se encontra abaixo do valor de referência de 0,4 mGy, o que limita a avaliação do desempenho dos modelos em faixas de dose mais elevadas. Dessa forma, recomenda-se a inclusão de dados com maior variabilidade de dose em estudos futuros para validação mais abrangente dos modelos. Do ponto de vista clínico, a Figura 4 evidencia que o RFR apresentou maior variabilidade em doses elevadas, com tendência de superestimação próxima ao limite de 0,4 mGy definido pela IN nº 90/2021 da ANVISA achado crítico por envolver risco adicional ao paciente. A RNA, por sua vez, manteve maior estabilidade nessas faixas, indicando melhor aderência aos valores observados. Ressalta-se, contudo, que este é um estudo experimental com base limitada (150 exames), sendo necessária a inclusão de um número maior de amostras, especialmente em doses mais altas, para calibrar melhor o RFR e consolidar os resultados de ambos os modelos. A tabela 2 contextualiza os achados com trabalhos prévios que aplicaram algoritmos de aprendizado de máquina na estimativa de dose em diferentes modalidades radiológicas. A maior parte dos estudos está concentrada em tomografia computadorizada (Yu *et al.*, 2025) e radioterapia (Ramlah *et al.*, 2023), explorando variáveis como kV, mAs, imagens de TC e parâmetros de planejamento. Em radiografias de tórax, Lin *et al.* (2025) investigaram predição de parâmetros de exposição, enquanto Mori *et al.* (2025) avaliaram técnicas de redução de dose por meio de redes neurais.

Diferentemente desses, o presente trabalho aplicou RNA e RFR para prever a DEP em radiografias de tórax em PA a partir de fatores radiográficos reais (kV, mAs, DFF e espessura torácica), oferecendo uma alternativa prática baseada em dados clínicos e reforçando o potencial do *machine learning* como ferramenta de apoio à física médica.

Tabela 2. Revisão de estudos prévios sobre predição de dose em exames radiológicos.

Estudo	Aplicação	Algoritmo	Variáveis	Métrica
Ramlah <i>et al.</i> (2023)	IMRT	Random Forest	Planejamento	MAE 0,012–0,270 cGy
Yu <i>et al.</i> (2019)	TC gestantes	CNN + MC	Imagens CT, anatômicas	Erro < 5%
Lin <i>et al.</i> (2025)	RX tórax	CNN / ML	Espessura, peso, altura, mAs	Predição mAs
Mori <i>et al.</i> (2025)	RX tórax	DL-Noise	Imagens RX + técnica	Redução dose* RNA: 0,008–0,991 RFR: 0,022–0,765
Este estudo (2025)	RX tórax PA	RNA, RFR	mAs, kV, DFF, espessura	

*Valores apresentados como MAE (mGy) e coeficiente de determinação (R^2) respectivamente.

Fonte: O autor (2026).

5. Conclusões

Este estudo demonstrou a viabilidade da aplicação de algoritmos de aprendizado de máquina na predição da DEP em radiografias de tórax em PA. Os resultados reforçam o potencial desses algoritmos como ferramentas de apoio à radioproteção, contribuindo para a otimização dos parâmetros técnicos, a redução da exposição desnecessária e a conformidade com diretrizes como a IN nº 90/2021 da ANVISA, que estabelece 0,4 mGy como dose de referência para exames de tórax em PA.

Os resultados indicam que a RNA apresentou capacidade preditiva superior em relação ao RFR, com menor erro preditivo e maior coeficiente de determinação (R^2 próximo de 1,0). Esse desempenho reforça sua maior precisão para estimar a DEP a partir dos fatores técnicos avaliados. No entanto, destaca-se como limitação do estudo o tamanho reduzido da base de dados (150 exames), o que pode restringir a generalização dos achados e indica a necessidade de validação em amostras maiores e mais diversificadas.

Como proposta para estudos futuros, sugere-se a ampliação da base de dados, incluindo não apenas um maior número de registros, mas também características clínicas dos pacientes (como idade, sexo, peso e altura). Essa integração permitirá desenvolvimento de modelos mais robustos e capazes de realizar predições diretamente a partir das imagens aproximando ainda mais o aprendizado de máquina da prática clínica e da tomada de decisão em tempo real.

Agradecimentos

Os autores agradecem ao Laboratório de Monitoração de Processos da COPPE/UFRJ pelo suporte técnico e pela infraestrutura disponibilizada para o desenvolvimento deste estudo. Agradecem também ao Instituto de Engenharia Nuclear (IEN/CNEN) pelo apoio institucional.

Referências

1. Bushberg JT, Seibert JA, Leidholdt EM, Boone JM. The essential physics of medical imaging. 3rd ed. Philadelphia: Lippincott Williams & Wilkins; 2012. 663–665.
2. International Atomic Energy Agency. Radiation protection and safety in medical uses of ionizing radiation. Specific Safety Guide SSG-46. Vienna: IAEA; 2018. p. 10–12.

3. Dance DR, Christofides S, Maidment ADA, McLean ID, Ng KH, eds. Diagnostic Radiology Physics: A Handbook for Teachers and Students. Vienna: International Atomic Energy Agency; 2014.
4. International Atomic Energy Agency. Radiation protection in diagnostic radiology. Safety Reports Series No. 457. Vienna: IAEA; 2018.
5. International Commission on Radiological Protection – ICRP. Recommendations of the International Commission on Radiological Protection. Annals of the ICRP, v. 34(1) (1991).
6. Agência Nacional de Vigilância Sanitária – ANVISA. Instrução normativa - IN nº 90, de 27 de maio (2021). Diário Oficial da União, nº 101, 31 de maio (2021).
7. Agência Nacional de Vigilância Sanitária (Brasil). Resolução RDC nº 611, de 9 de fevereiro de 2022. Dispõe sobre os requisitos sanitários para serviços de radiologia diagnóstica ou intervencionista. Diário Oficial da União [Internet]. 2022 fev 10 [citado 2025 out 6]; Seção 1:145–56.
8. Haykin, S. S. Neural networks and learning machines. [S.l.]: Pearson Upper Saddle River, NJ, USA, 2009. v. 3.
9. Abdo RC, Umisedo NK, Campos LT, Costa PR. Assessment of organ absorbed doses in patients undergoing chest X-ray examinations by Monte Carlo based softwares and phantom dosimetry. Radiat Meas. 2011;46(12):1981–1984. doi: 10.1016/j.radmeas.2011.07.017.
10. Yu H, Scalzo F, Zbijewski W, Sturgeon G, Tward DJ. Automated fetal dose estimation in CT using convolutional neural networks and Monte Carlo simulations. Phys Med Biol. 2019;64(17):175005. doi:10.1088/1361-6560/ab332c.
11. Lin C, Hsieh Y, Lin Y, Hsu C, Chen J, et al. An artificial intelligence model for predicting an appropriate mAs with target exposure indicator for chest digital radiography. Sci Rep. 2025;15:1060. doi:10.1038/s41598-025-96947-y
12. Mori I, Nishio M, Sugiyama O, Onishi H. Reduction of radiation exposure in chest radiography using deep learning-based noise reduction. J Radiol Prot. 2025 Feb 3;45(1):012501. doi:10.1088/1361-6498/ad8a8b.
13. Isnawan K, Ardiansyah R, Suherman S. Identifikasi paparan radiasi X-Ray untuk keselamatan radiasi menggunakan Random Forest classification. Jurnal Teknik. 2023;8(2):75–81. doi:10.52561/teknika.v8i2.288.
14. Ferrante M, De Marco P, Rampado O, Gianusso L, Origgi D. Effective dose estimation in computed tomography by machine learning. Tomography. 2025 Jan 2;11(1):2. doi:10.3390/tomography1101002.
15. Ramlah R, Fadli M, Valerian J, Prajitno P, Sihono DSK. Random-Forest Model Prediction of Dose Distribution in Intensity-Modulated Radiation Therapy (IMRT) Planning for Lung Cancer. Iranian Journal of Medical Physics. 2023;20(5):298–304. doi:10.22038/ijmp.2022.64319.2101
16. Wambersie A, Zoetelief J, Menzel HG, Paretzke P. The ICRU (International Commission on Radiation Units and Measurements): its contribution to dosimetry in diagnostic and interventional radiology. Radiat Prot Dosimetry. 2005;117(1–3):7–12
17. Chakraborty S. Fundamentals of Machine Learning and Deep Learning. 1st ed. Cham: Springer; 2021.

Contato:

Gustavo Oliveira da Conceição

Programa de Engenharia Nuclear PEN-UFRJ
Avenida Horácio de Macedo 2030, Bloco G - Sala 206, CEP 21941-914, Cidade Universitária, RJ, Brasil

E-mail gconceicao@nuclear.ufrj.br