

# Redes Neurais para Tomografia de Plasmas em Reatores de Fusão Nuclear

Diogo D. Carvalho, Diogo R. Ferreira, Horácio Fernandes

*Instituto de Plasmas e Fusão Nuclear, Instituto Superior Técnico, Universidade de Lisboa, 1049-001 Lisboa, Portugal*

diogo.d.carvalho@tecnico.ulisboa.pt, diogo.ferreira@tecnico.ulisboa.pt, hf@ipfn.tecnico.ulisboa.pt

**Resumo**—O principal objetivo da investigação em fusão nuclear é conseguir recriar de forma controlada as reações que acontecem no interior das estrelas, de modo a produzir energia virtualmente ilimitada e sem impacto para o ambiente. Para isto acontecer, é necessário desenvolver reatores capazes de confinar o plasma criado ao atingir as temperaturas exigidas para a produção auto-sustentável de reações de fusão. É portanto importante desenvolver variados métodos de diagnóstico que permitam monitorizar todos os fenómenos que acontecem dentro destes reatores. Um exemplo de tal diagnóstico é a tomografia que permite reconstruir o perfil 2D de radiação do plasma que está, entre outros, relacionado com a temperatura e densidade do mesmo. No entanto, devido ao número reduzido de linhas de visão disponíveis, obter tomogramas com a resolução necessária é atualmente um processo moroso. Neste trabalho demonstramos como a utilização de redes neuronais aplicado ao sistema de raios X do reator COMPASS permite realizar estas reconstruções num tempo de computação substancialmente inferior, mantendo uma qualidade equivalente à dos algoritmos existentes.

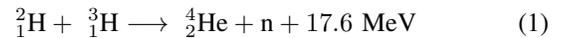
**Index Terms**—Física dos Plasmas, Tomografia Computorizada, Computação em Placas Gráficas, Aprendizagem Profunda

## I. INTRODUÇÃO

As reações de fusão acontecem quando dois núcleos atómicos se aproximam o suficiente para que a força nuclear forte que os aproxima exceda a força eletrostática que os separa. O resultado de tal reação é então um núcleo mais pesado e possivelmente outros produtos como neutrões. Para elementos de número atómico inferior ao ferro-56 ( $^{56}\text{Fe}$ ) esta é uma reação exotérmica, pelo que é possível extrair energia do sistema após a reação. Contudo, é necessário fornecer energia ao sistema para permitir que os átomos atinjam distâncias suficientemente pequenas para se dar a reação. Devido à quantidade de energia fornecida, os átomos são ionizados criando uma mistura de iões positivos, eletrões livres e átomos neutros a que se dá o nome de *plasma*. Todos estes fenómenos acontecem naturalmente nas estrelas onde o principal combustível disponível é o hidrogénio, sendo o confinamento do plasma e temperaturas necessária garantidos pela campo gravítico.

Este trabalho foi realizado no âmbito da associação EUROfusion tendo recebido financiamento do programa Euratom para investigação e treinamento 2014-2018 ao abrigo do acordo nr. 633053. As opiniões expressas neste trabalho não refletem necessariamente as da Comissão Europeia. As atividades desenvolvidas pelo IPFN receberam apoio financeiro da Fundação para a Ciência e Tecnologia (FCT) através do projeto UID/FIS/50010/2013. O trabalho desenvolvido na experiência COMPASS foi financiado pelo programa de estágios para estudantes de mestrado na área de fusão realizado pela FuseNet. A placa gráfica Titan X utilizada neste trabalho foi doada pela NVIDIA Corporation.

Ao tentar replicar este processo na Terra é importante decidir qual a reação de fusão a utilizar, tendo em conta aspectos como recursos naturais existentes e rendimento energético. Atualmente, a reação que se apresenta como melhor candidata é [1]:



na qual *deutério* ( ${}^2_1\text{H}$ ) e *trítio* ( ${}^3_1\text{H}$ ) geram um núcleo de hélio e um neutrão, libertando adicionalmente uma quantidade relativamente grande de energia.

Uma vez que não possuímos capacidade de recriar os campos gravíticos que se fazem sentir numa estrela, é necessário desenvolver reatores que confinem o plasma a temperaturas elevadíssimas ( $\approx 10$  vezes superiores à temperatura do Sol). Atualmente existem diversos modelos de reatores [2], sendo o mais promissor denominado *tokamak* [3]. Num tokamak o plasma é confinado dentro de um câmara de formato toroidal, através de campos magnéticos toroidais e poloidais gerados por bobines. Um exemplo de tal dispositivo é o reator COMPASS [4] instalado na República Checa.

Para efeitos de controlo e estudo dos fenómenos físicos que acontecem dentro do reator, é necessário desenvolver métodos de diagnóstico que permitam monitorizar quantidades como a densidade, a temperatura e a radiação emitida. Esta última pode ser obtida com recurso a sistemas de tomografia.

### A. Tomografia de plasmas

Ao contrário do que acontece em medicina, na tomografia de plasmas a fonte da radiação coletada é o próprio plasma. Esta radiação é gerada por vários mecanismos, nomeadamente transições entre níveis energéticos, recombinação eletrónica e *bremstrahlung* [1]. Para as frequências nas quais esta emissão acontece é tipicamente assumido que o plasma é transparente à radiação, não existindo portanto reabsorção da radiação emitida.

Dependendo dos detetores utilizados é possível medir diferente regiões do espectro. Por exemplo, o COMPASS possui um sistema de 3 câmaras para deteção de raios X com um total de 90 linhas de visão (Figura 1) e uma frequência de aquisição máxima de 2 MHz. Normalmente é feita uma média dos valores usando uma janela temporal para reduzir o efeito do ruído, acabando por se utilizar uma frequência efetiva que ronda  $\approx 1$  kHz.

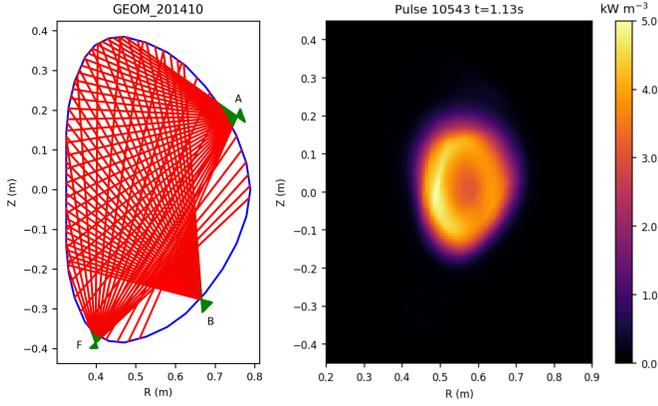


Figura 1. Sistema tomográfico de raios X disponível no reator COMPASS composto por 3 câmaras (A,B,F a verde). As câmaras estão localizadas ao longo de uma secção poloidal do reator (azul) onde o plasma se encontra confinado (esquerda). Exemplo de reconstrução do perfil de radiação 2D do plasma para o pulso 10543 em  $t = 1.13$  s (direita).

Cada um destes detetores medirá um certo valor de radiação  $f_i$  [ $\text{W m}^{-2}$ ] ao longo de uma linha de visão  $l_i$ . Este valor pode ser aproximado por:

$$f_i = \int_{l_i} g \cdot dl, \quad i = 1, \dots, N \quad (2)$$

onde  $N$  representa o número de detetores disponíveis e  $g$  [ $\text{W m}^{-3}$ ] o perfil 2D de radiação do plasma que pretendemos recuperar (exemplo na Figura 1). No entanto, este sistema de equações na forma integral é indeterminado, dado que seria necessário um número infinito de detetores para encontrar uma solução única para  $g$ . Apesar disto, existem vários algoritmos que permitem utilizar informação disponível *a priori* sobre a solução, de modo a calcular um tomograma.

Atualmente, os algoritmos mais promissores são baseados em *regularização de Tikhonov* [5], nomeadamente em *regularização mínima de Fisher* (MFR), nos quais é forçado um gradiente suave dos valores de  $g$  ao longo das superfícies de fluxo magnético do plasma (onde se espera que a densidade e temperatura seja aproximadamente constantes). Este é precisamente o algoritmo utilizado no COMPASS [6], com o qual se obtêm reconstruções com uma resolução de  $135 \times 105$  pixels.

Devido à natureza iterativa destes algoritmos, e à necessidade de inversão de grandes matrizes, o tempo de computação de uma reconstrução é substancial (no caso do COMPASS entre 1–10 s). Isto impossibilita não só a criação de sistemas de tomografia em tempo real (centenas de  $\mu\text{s}$  a ms) mas também torna a análise de um experiência num processo bastante moroso. Por exemplo, no caso do COMPASS um pulso demora  $\approx 1$  s, o que implicaria  $\approx 10^3$  reconstruções e 17–170 min para realizar todos os cálculos necessários.

Por estes motivos, é necessário encontrar alternativas de modo a reduzir substancialmente o tempo de computação. As redes neuronais surgem então como um forte candidato para esta tarefa, dado que após serem treinadas conseguem calcular novas reconstruções utilizando operações paralelizáveis.

## B. Redes neuronais

Tal como muitas outras áreas, que vão desde o processamento de imagem ao processamento de língua natural, já existem aplicações bem sucedidas de redes neuronais em tomografia de plasmas em reatores como o ISTTOK [7] e o JET [8]–[10]. O objetivo destas redes passa por gerar tomogramas a partir dos valores dos detetores. Para as treinar é necessário recorrer a bases de dados de reconstruções realizadas com outros algoritmos. É portanto de extrema importância que estes tomogramas incluam não só um leque de situações variadas, bem como soluções isentas de artefactos, nomeadamente fontes de radiação em locais onde não faz sentido as mesmas existirem ou linhas de visão muito demarcadas.

Neste trabalho treinamos uma rede neuronal para o sistema de raios X do COMPASS, algo nunca antes realizado para este tipo de diagnóstico utilizando medidas reais. Esta rede neuronal baseia-se na arquitetura mais recente desenvolvida para o sistema bolométrico do JET [8], tendo sido realizadas as alterações necessárias para a adaptar ao novo diagnóstico, otimizando a qualidade das reconstruções e os tempos de computação.

## II. REDE NEURONAL

A rede neuronal desenvolvida para o COMPASS (Figura 2) possui 90 entradas (correspondentes ao número de detetores) seguida de duas camadas densas e um redimensionamento para um volume 3D. Em seguida quatro camadas de convoluções transpostas definidas por um *kernel* ( $k$ ) e *stride* ( $s$ ) permitem obter no final uma imagem com uma resolução de  $136 \times 104$  pixels. Todas as camadas utilizam a função retificadores lineares (*ReLU*) como função de ativação.

A resolução final difere ligeiramente da resolução dos tomogramas produzidos pelo COMPASS ( $135 \times 105$ ), o que é resolvido adicionando uma linha de zeros aos tomogramas originais e removendo uma coluna. A remoção da coluna não é problemática dado que o limite da reconstrução corresponde a pixels que estão fora do reator, pelo que não têm radiação associada. Esta rede neuronal foi implementada em Python utilizando as bibliotecas Keras [11] e Theano [12], permitindo assim a paralelização de cálculos numa placa gráfica. Todas as computações apresentadas foram realizadas com recurso a uma Nvidia Titan X e um processador Intel i7-3820.

Para treinar a rede recolheram-se 5 784 tomogramas gerados pelo algoritmo MFR para experiências (pulsos) no intervalo 9860–11150. Estes dados foram divididos em 3 grupos para treino/validação/teste de acordo com o rácio 80% / 10% / 10%. Como algoritmo de otimização utilizou-se o Adam [13] com uma taxa de aprendizagem  $10^{-4}$  e como função-objectivo o erro absoluto médio. O conjunto de treino foi dividido em 10 partes, com aproximadamente 435 reconstruções cada. Deste modo são realizadas 10 iterações de otimização ao longo de uma época de treino.

Os parâmetros finais escolhidos para a rede correspondem aos obtidos na época 25 682 onde foi atingido, após 86 horas de treino, o erro mínimo no conjunto de validação de  $0.0054 \text{ kW m}^{-3}$ .

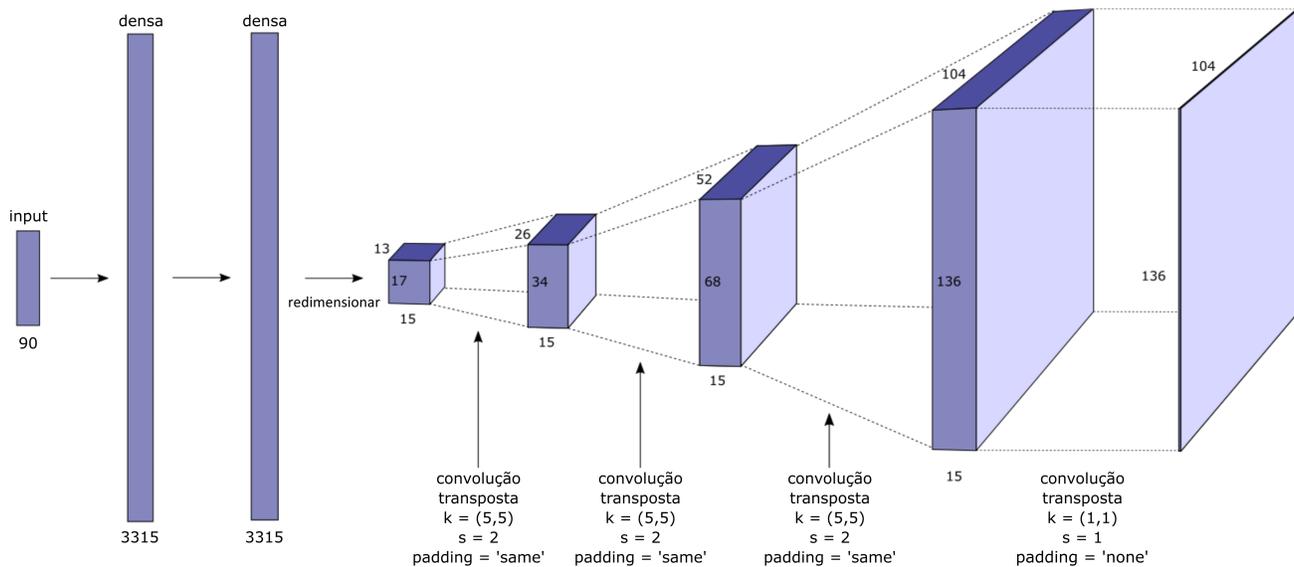


Figura 2. Rede Neural desenvolvida para o sistema de raios X do COMPASS.

### A. Geração de novas reconstruções

Após o treino da rede é importante aferir a qualidade das novas reconstruções. Para tal foram usadas métricas que comparam a reconstrução produzida pela rede neuronal com a reconstrução produzida pelo algoritmo MFR. As métricas usadas neste trabalho são:

- *Structural similarity* (SSIM) [14], mede a similaridade entre duas imagens ao longo de várias janelas. Está definida entre 0 e 1, onde 1 indica que as imagens são iguais.
- *Peak signal to noise ratio* (PSNR) [15], utilizado normalmente para comparar a qualidade entre uma imagem e a sua versão comprimida. É uma medida logarítmica expressa em decibéis (dB).
- *Normalized root mean squared error* (NRMSE) [16].

Várias comparações entre os tomogramas produzidos pela rede neuronal *versus* tomogramas originais são apresentados na Figura 3. As métricas obtidas para estes casos bem como para todo o conjunto de teste estão disponíveis na Tabela I. Os valores médios elevados de SSIM e PSNR bem como o valor residual de NRMSE permitem concluir que a rede neuronal produz reconstruções bastante semelhantes às realizadas pelo algoritmo original. Isto acontece não só para os perfis usuais nos quais o plasma está centrado com o reator (pulso 10165)

bem como para casos em que se move consideravelmente (pulsos 10666 e 10766).

Quanto ao tempo necessário para calcular uma reconstrução é em média  $\approx 1$  ms. Este valor representa um ganho significativo em relação ao tempo do algoritmo MFR ( $\approx 1$  s).

### B. Aprendizagem com detetores avariados

Por vezes, pode acontecer que um detetor deixe de funcionar corretamente ou deixe de todo de medir. É do nosso interesse, que nesses casos, seja possível continuar a produzir reconstruções fidedignas sem ser necessário treinar novamente a rede. Para resolver este problema, durante cada iteração de treino um certo conjunto de detetores escolhidos de forma aleatória é desligado. Este processo é denominado por *dropout* [17] e é normalmente utilizado em camadas mais profundas de redes neuronais para evitar *overfitting*. Neste caso, não pretendemos prevenir *overfitting*, mas sim permitir à rede extrapolar a informação necessário para a reconstrução, sem ter acesso a todos os detetores que estavam disponíveis originalmente.

O desempenho deste método foi avaliado da seguinte forma. Desligou-se um detetor de cada vez para todo o conjunto de teste e de seguida calcularam-se todas as reconstruções e correspondentes métricas. O mesmo processo foi repetido para todas as combinações possíveis de dois detetores.

De todos os valores de *dropout* testados (0.01, 0.05 e 0.10) obtiveram-se melhor resultados com uma taxa de 0.01. A comparação entre o desempenho da rede treinada com *dropout* em comparação com a rede treinada normalmente é apresentada na Tabela II. Observa-se que a nova rede atinge um desempenho semelhante à original no caso em que nenhum detetor deixa de funcionar. Além disso, a rede treinada com *dropout*, mantém um desempenho semelhante nos casos em que os detetores são desligados. Valores mais altos de *dropout* (0.05 e 0.10) não conseguiram produzir melhorias.

Tabela I  
MÉTRICAS OBTIDAS PARA AS RECONSTRUÇÕES PRESENTES NA FIGURA 3  
E NO CONJUNTO DE TESTE COMPLETO

Pulso	SSIM	PSNR (dB)	NRMSE
10165	1.000	58.07	0.01
10666	0.991	43.67	0.12
10766	0.973	30.77	0.31
Conjunto de Teste	$0.998 \pm 0.004$	$49.96 \pm 4.63$	$0.02 \pm 0.02$

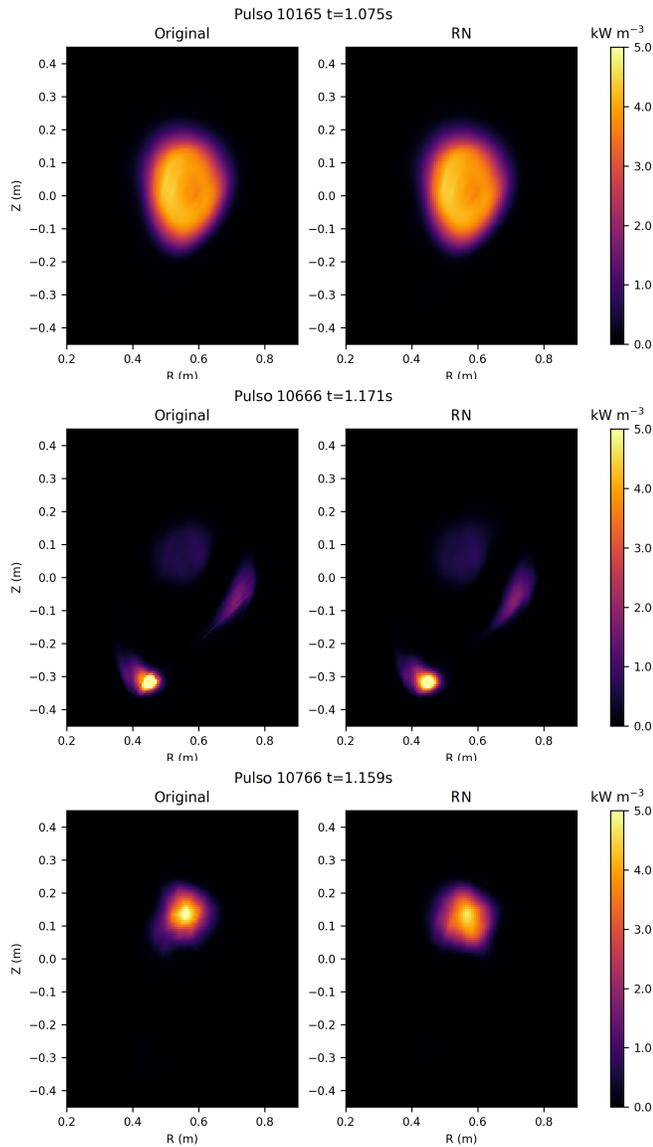


Figura 3. Comparação entre as reconstruções originais da base de dados do COMPASS com as reconstruções obtidas pela rede neuronal.

### III. CONCLUSÕES

Os resultados deste trabalho demonstram que a utilização de redes neurais permite reduzir significativamente o tempo necessário para calcular tomogramas (1 ms *versus* 1 s) mantendo uma qualidade semelhante à dos algoritmos existentes. É também demonstrado que, ajustando alguns dos seus parâmetros (tamanho das camadas, número de convoluções), a arquitetura desenvolvida para o sistema bolométrico do JET pode ser adaptada e treinada para diferentes reatores e diagnósticos de tomografia.

Foi também possível concluir que a introdução de um certo valor de *dropout* durante o treino permite à rede neuronal manter o desempenho quando alguns detetores deixam de funcionar, sem o prejudicar num regime de funcionamento normal. Assim adiciona-se mais um parâmetro ao modelo que,

Tabela II

MÉTRICAS OBTIDAS PARA A REDE NEURONAL, TREINADA COM E SEM DROPOUT, DEPOIS DE DESLIGADOS UM CERTO NÚMERO DE DETETORES. OS VALORES APRESENTADOS CORRESPONDEM À MÉDIA DE TODAS AS POSSÍVEIS COMBINAÇÕES DE DETETORES DESLIGADOS.

#Desligados	Dropout	SSIM	PSNR (dB)	NRMSE
0	0.01	0.999 ± 0.004	50.23 ± 4.23	0.02 ± 0.02
1	Nulo	0.987 ± 0.029	41.77 ± 8.79	0.07 ± 0.06
	0.01	0.996 ± 0.025	48.79 ± 6.06	0.02 ± 0.02
2	Nulo	0.983 ± 0.020	37.99 ± 7.84	0.10 ± 0.07
	0.01	0.998 ± 0.004	48.97 ± 4.22	0.03 ± 0.02

tal como outros, precisa de ser devidamente afinado.

O código desenvolvido no âmbito deste trabalho encontra-se disponível para a comunidade científica num repositório.<sup>1</sup>

### REFERÊNCIAS

- [1] F. F. Chen, *Introduction to Plasma Physics and Controlled Fusion*. Springer, 2016.
- [2] J. P. Freidberg, *Ideal MHD*. Cambridge University Press, 2014.
- [3] K. Lackner, S. Guenter, P. Lauber, G. Pautasso, and B. Scott, “Equilibrium and macroscopic stability of tokamaks,” in *Fusion Physics*. IAEA, 2012.
- [4] R. Pánek, O. Bilyková, V. Fuchs, M. Hron, P. Chráska, P. Pavlo, J. Stöckel, J. Urban, V. Weinzettl, J. Zajac *et al.*, “Reinstallation of the COMPASS-D tokamak in IPP ASCR,” *Czechoslovak Journal of Physics*, vol. 56, no. 2, pp. B125–B137, 2006.
- [5] J. Mlynar, T. Craciunescu, D. R. Ferreira, P. Carvalho, O. Ficker, O. Grover, M. Imrisek, and J. Svoboda, “Current research into applications of tomography for fusion diagnostics,” *Journal of Fusion Energy*, 2018.
- [6] J. Mlynar, M. Imrisek, V. Weinzettl, M. Odstrcil, J. Havlicek, F. Janky, B. Alper, and A. Murari, “Introducing minimum Fisher regularization tomography to AXUV and soft x-ray diagnostic systems of the COMPASS tokamak,” *Review of Scientific Instruments*, vol. 83, no. 10, p. 10E531, 2012.
- [7] P. Carvalho, “Tomography Algorithms for Real-Time Control in IST-TOK,” Ph.D. dissertation, Universidade Técnica de Lisboa, Instituto Superior Técnico, 2010.
- [8] D. R. Ferreira, P. J. Carvalho, and H. Fernandes, “Full-pulse tomographic reconstruction with deep neural networks,” *Fusion Science and Technology*, vol. 74, no. 1–2, pp. 47–56, 2018.
- [9] F. A. Matos, D. R. Ferreira, and P. J. Carvalho, “Deep learning for plasma tomography using the bolometer system at JET,” *Fusion Engineering and Design*, vol. 114, pp. 18–25, 2017.
- [10] E. Ronchi, S. Conroy, E. A. Sundén, G. Ericsson, M. G. Johnson, C. Hellesen, H. Sjöstrand, and M. Weiszflog, “Neural networks based neutron emissivity tomography at JET with real-time capabilities,” *Nuclear Instruments and Methods in Physics Research Section A*, vol. 613, no. 2, pp. 295–303, 2010.
- [11] F. Chollet, *Deep Learning with Python*. Manning Publications, 2017.
- [12] R. Al-Rfou *et al.*, “Theano: A Python framework for fast computation of mathematical expressions,” *arXiv e-prints*, May 2016. [Online]. Available: <http://arxiv.org/abs/1605.02688>
- [13] D. P. Kingma and J. Ba, “Adam: A method for stochastic optimization,” *arXiv preprint*, 2014. [Online]. Available: <https://arxiv.org/abs/1412.6980>
- [14] Z. Wang, A. C. Bovik, H. R. Sheikh, and E. P. Simoncelli, “Image quality assessment: from error visibility to structural similarity,” *IEEE transactions on image processing*, vol. 13, no. 4, pp. 600–612, 2004.
- [15] Q. Huynh-Thu and M. Ghanbari, “Scope of validity of PSNR in image/video quality assessment,” *Electronics Letters*, vol. 44, no. 13, pp. 800–801, 2008.
- [16] J. R. Fienup, “Invariant error metrics for image reconstruction,” *Applied Optics*, vol. 36, no. 32, pp. 8352–8357, 1997.
- [17] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, “Dropout: A simple way to prevent neural networks from overfitting,” *Journal of Machine Learning Research*, vol. 15, no. 1, pp. 1929–1958, 2014.

<sup>1</sup><https://github.com/diogodcarvalho/PlasmaTomoML>