

# **Revisão sistemática da literatura sobre a utilização de *Convolutional Neural Networks* para detecção de nódulos pulmonares em imagens de tomografia computadorizada**

Joyce Moura Silva<sup>1</sup>

<sup>1</sup>Programa de Pós-Graduação em Engenharia Elétrica  
Universidade Federal do Piauí (UFPI) – Teresina – PI – Brasil

joyzinhw@gmail.com

**Abstract.** Lung cancer is one of the leading causes of mortality worldwide, as pointed out by the International Agency for Research on Cancer (IARC). Computed tomography is widely used to detect lung nodules, but manual analysis of these images is challenging due to the complexity and large volume of data. CNNs have been used to improve automatic nodule detection, demonstrating great effectiveness in identifying complex patterns in medical images. This study conducts a Systematic Literature Review in order to understand trends in the use of CNNs in the detection of pulmonary nodules and analyze these architectures and databases.

**Resumo.** O câncer de pulmão é uma das principais causas de mortalidade no mundo, como apontado pela Agência Internacional de Pesquisa em Câncer (IARC). A Tomografia Computadorizada é amplamente utilizada para detecção de nódulos pulmonares, mas a análise manual dessas imagens é desafiadora devido à complexidade e ao grande volume de dados. As CNNs têm sido empregadas para aprimorar a detecção automática de nódulos, demonstrando grande eficácia na identificação de padrões complexos em imagens médicas. Este estudo realiza uma Revisão Sistemática da Literatura a fim de entender as tendências no uso de CNNs na detecção de nódulos pulmonares, analisando essas arquiteturas e bases de dados.

## **1. Introdução**

O câncer é a nomenclatura atribuída a um grupo superior a 100 doenças que apresentam em comum o desenvolvimento descontrolado de células, as quais penetram tecidos e órgãos<sup>1</sup>. Segundo o Instituto Nacional de Câncer (INCA)<sup>2</sup>, as estimativas de 2023 sobre o tumor pulmonar trouxeram as informações de que o mesmo é o terceiro mais comum em homens, com 18.020 casos novos e o quarto em mulheres no Brasil, tendo 14.540 casos novos, e é o primeiro em todo o mundo em incidência entre os homens e o terceiro entre as mulheres. Representando uma das principais causas de morte no mundo, o câncer de pulmão foi responsável por 1,8 milhão de óbitos em 2022<sup>3</sup>.

A Tomografia Computadorizada (TC) é um dos métodos mais eficazes para diagnóstico inicial para tumores, sendo um exame não invasivo que gera imagens detalhadas de alta qualidade em tons de cinza, usadas na análise de diversas lesões, incluindo

<sup>1</sup><https://www.gov.br/inca/pt-br/assuntos/cancer/o-que-e-cancer>

<sup>2</sup><https://www.gov.br/inca/pt-br/assuntos/cancer/tipos/pulmao>

<sup>3</sup><https://gco.iarc.fr/today/en/fact-sheets-populations#global>

as pulmonares [Dolejší 2007], sendo o método favorito dos especialistas por tais feitos, como dito por [Yan et al. 2016]. Todavia, a detecção de nódulos pulmonares em tais imagens requer uma análise aprofundada, que pode ser exaustiva devido ao grande número de imagens e à necessidade de distinguir estruturas pulmonares de outros órgãos e tecidos.

Nos casos de uso de TC, essas imagens medicas são naturalmente complexas, o que exige habilidade e experiência profissional do médico [Kamiya et al. 2011]. No entanto, identificar e classificar nódulos em estágios iniciais pode ser uma tarefa difícil até mesmo para profissionais da medicina com muita experiência, pois nódulos de tamanho reduzido apresentam baixo contraste e podem estar localizados em áreas com cores semelhantes, tornando assim mais complicado o processo de distinção entre nódulos cancerígenos e não cancerígenos [Silva et al. 2005].


Nos últimos anos, as CNNs (do inglês, *Convolutional Neural Networks*) têm se destacado pela sua atuação na identificação de nódulos pulmonares em imagens tomográficas, por sua capacidade de identificar padrões sutis e complexos nas imagens [Xie et al. 2019, Eun et al. 2018, Jiang et al. 2018]. Essa abordagem vai além dos métodos tradicionais, pois é capaz de analisar diversos aspectos da imagem, como textura, densidade e tamanho das estruturas, permitindo uma comparação mais precisa entre as imagens e o reconhecimento de padrões.

Diante disso, este trabalho propõe uma Revisão Sistemática da Literatura (RSL) sobre a utilização de CNNs para identificar nódulos em imagens de TC, com o objetivo de analisar os principais avanços na detecção automatizada de nódulos pulmonares, avaliando aspectos como as características das CNNs e das bases de dados utilizadas, as motivações para o uso e a relevância dos artigos. Esta revisão busca fornecer um panorama abrangente do estado da arte, pois de acordo com [Kitchenham 2004], todos os estudos de pesquisas sejam eles científicos ou não, deveriam abordar inicialmente a revisão sistemática para então serem conduzidos sobre uma base de evidências consolidadas.

## 2. Metodologia

Este trabalho possui um caráter exploratório, uma vez que busca aprofundar um assunto fundamentando-se em estudos acadêmicos previamente publicados, o que está de acordo com o protocolo proposto por [Kitchenham and Charters 2007], que estabelece que uma RSL deve ser dividida em três fases: planejamento, condução e documentação.

Durante a etapa de planejamento, foram estabelecidos os propósitos da revisão, as perguntas de pesquisa, as fontes de informação e os critérios para a inclusão e exclusão dos estudos. Na etapa de execução, foram implementadas táticas de busca específicas, feitas leituras e extração, e a tabulação dos dados para abordar as perguntas que foram levantadas. Finalmente, na fase de documentação, os dados foram examinados e estruturados em um relatório final. A Figura 1 ilustra o processo de uma RSL.



**Figura 1. Fases de uma revisão sistemática e mapeamento sistemático.**  
[Scannavino et al. 2017]

## 2.1. Planejamento

### 2.1.1. Questões de pesquisa

Esta RSL tem finalidade de mapear os estudos acadêmicos sobre a utilização de CNNs para detecção de nódulos pulmonares com base em imagens de tomografia computadorizada, criando uma base teórica para futuros desenvolvimentos na área. Foram estabelecidas as questões de pesquisa abaixo a serem abordadas através da coleta de informações dos estudos:

Questão 1 (Q1) - Quais CNNs vêm sendo mais utilizadas para detecção de nódulos pulmonares ?

Questão 2 (Q2) - Por quais motivos são utilizadas combinações híbridas de CNNs com outras arquiteturas ou abordagens?

Questão 3 (Q3) - Quais bases de dados foram utilizadas para essa tarefa?

### 2.1.2. Fontes de dados

Inicialmente, para buscar as literaturas que compõem a RSL, utilizamos o Portal de Periódicos da CAPES<sup>4</sup>, que é uma biblioteca virtual que reúne e disponibiliza conteúdo científico a instituições de ensino e pesquisa no Brasil. Assim, foi possível realizar uma análise das fontes mais adequadas, uma vez que essas plataformas oferecem mecanismos de pesquisa avançada que interpretam expressões booleanas e disponibilizam uma variedade de estudos na área. Após essa verificação, as fontes de dados foram selecionadas, conforme apresentado na Tabela 1.

<sup>4</sup><https://www.periodicos.capes.gov.br/>

**Tabela 1. Fontes de dados selecionadas.**

Fonte de dados	Link
Scopus	<a href="https://www.scopus.com">https://www.scopus.com</a>
Pubmed	<a href="https://pubmed.ncbi.nlm.nih.gov">https://pubmed.ncbi.nlm.nih.gov</a>
Web Of Science	<a href="https://www.webofscience.com">https://www.webofscience.com</a>
IEEE Xplore	<a href="https://ieeexplore.ieee.org/Xplore/home.jsp">https://ieeexplore.ieee.org/Xplore/home.jsp</a>

### **2.1.3. Critérios de inclusão e exclusão**

Esta seção foram definidos alguns critérios para incluir os trabalhos que serão examinados, bem como excluir os estudos que fogem ao propósito final dessa RSL e não respondem as questões de pesquisa. A Tabela 2 mostra os critérios de inclusão e exclusão levados para filtrar os estudos.

**Tabela 2. Critérios de Inclusão e Exclusão.**

Critérios de Inclusão	Critérios de Exclusão
Artigos originais	Pesquisas secundárias (RSL/MSL)
Publicados entre 2020 e 2025	Estudos fora do período definido
Idioma inglês	Outros idiomas
Acesso aberto	Acesso restrito/pago
Uso de CNNs puras ou híbridas	Utiliza outras técnicas
Foco em nódulos pulmonares	Aborda outros tipos de câncer/lesões/doenças
Utilizar imagens de tomografia (TC)	Outras modalidades de imagem (raio-X, MRI)
Utilizar apenas bases de dados públicas	Base de dados privada ou não especificadas
Relata acurácia/métricas de desempenho	Sem dados quantitativos

## **2.2. Condução**

### **2.2.1. Busca dos trabalhos**


Para buscar os trabalhos nas fontes selecionadas foi necessário a criação de uma *string* de busca, que funciona em todas as fontes selecionadas, como demonstrado na Tabela 3.

**Tabela 3. String utilizada para a busca de artigos.**

String de Busca
((“Convolutional Neural Networks” OR “CNN” OR “Deep Learning” OR “Machine Learning”) AND (“Pulmonary Nodules” OR “Lung Nodules”) AND (“Computed Tomography” OR “CT Scan” OR “Medical Imaging”) AND (“Detection” OR “Lung Nodules Detection”))

### **2.2.2. Estratégia de seleção**

Visando alcançar o objetivo de melhorar o gerenciamento das propriedades a serem empregadas na RSL, organizou-se essa seleção em quatro etapas, como ilustrado na Figura 2.



**Figura 2.** Estratégia de seleção proposta.

A primeira etapa iniciou-se com uma pesquisa utilizando apenas as *strings* de busca propostas na Tabela 3 nos repositórios escolhidos, retornando 1.527 artigos, no total. Em seguida, na segunda fase, foi realizada uma busca avançada ainda utilizando as bases de dados, aplicando os critérios de inclusão (CI) e os critérios de exclusão (CE). Dessa forma, restaram 450 artigos, como observado na Tabela 4.

**Tabela 4.** Fontes de dados selecionadas.

Fonte de dados	Qtd de resultados	Qtd apóis CI e CE
Scopus	628	223
Pubmed	336	95
Web Of Science	563	93
IEEE Xplore	628	39

Na terceira etapa, foram removidos os artigos duplicados utilizando a ferramenta *Rayyan*<sup>5</sup>, criada por [Johnson and Phillips 2018], que oferece uma detecção precisa de duplicatas [Guimarães et al. 2022, McKeown and Mir 2021]. Após essa filtragem, remanesceram 319 artigos.

Na quarta e última etapa, foi realizada uma revisão manual com base nos critérios CI e CE, envolvendo a leitura dos títulos, palavras-chave, resumos e metodologias, com o objetivo de manter apenas os estudos alinhados à proposta da pesquisa. Ao final dessa etapa, restaram 23 artigos, os quais passaram por uma seleção criteriosa que assegurou uma análise rigorosa dos trabalhos, alinhados ao tema e com metodologias robustas, garantindo a qualidade e a relevância dos resultados apresentados. Os artigos restantes foram lidos integralmente e organizados em uma planilha<sup>6</sup> contendo título dos trabalhos, autores, ano, base de dados e as CNNs utilizadas.

Por fim, os critérios de qualidade foram determinados pelos veículos de publicação dos artigos, os quais apresentaram metodologias bem definidas e adequadas aos problemas abordados, fazendo uso de conjuntos de dados robustos.

### 2.3. Documentação

Para a avaliação e exposição dos estudos escolhidos, foram enfatizados, em cada um deles, os tipos de CNNs empregadas, os conjuntos de dados de imagens tomográficas utilizados. Permitindo responder às questões de pesquisa e atingir o objetivo final desta RSL.

<sup>5</sup><https://www.rayyan.ai/>

<sup>6</sup><https://encurtador.com.br/w5jJK>


A seguir, na proximo seção trará os resultados detalhados do estudo, com gráficos e tabelas, facilitando a visualização e o entendimento.

### 3. Resultados

Após selecionar e analisar os estudos escolhidos, conseguimos responder às perguntas inicialmente propostas e atingir o propósito da revisão sistemática.

#### **Q1 - Quais CNNs vêm sendo mais utilizadas para detecção de nódulos pulmonares ?**

A base da primeira questão é apontar as CNNs mais utilizadas, sendo puras ou híbridas com outras arquiteturas e abordagens de *Deep Learning* (DL). A Figura 3 ilustra os resultados dos 23 trabalhos analisados. Ao todo, foram identificadas 17 arquiteturas distintas, das quais apenas 5 foram utilizadas mais de uma vez, com ênfase nas arquiteturas 3D, tanto em CNNs puras quanto híbridas. Além disso, vale destacar a presença de modelos pré-treinados, refletindo uma tendência no uso de técnicas de DL para aumentar a eficiência dos sistemas.



**Figura 3. CNNs mais utilizadas.**

Para contextualizar, as CNNs são uma arquitetura inspirada na biologia, capaz de aprender hierarquias de diferentes níveis de características [LeCun et al. 1998]. Elas foram projetadas para processar dados em forma de grades, como imagens, viabilizando a extração automática de padrões espaciais e das hierarquias de características [Li et al. 2021], permitindo, portanto, uma comparação mais precisa entre as imagens e um reconhecimento mais eficiente de padrões. Desde a sua criação, as CNNs provaram ser muito eficazes para resolver problemas de classificação e detecção, mostrando-se uma alternativa viável aos métodos tradicionais para esse tipo de problema.

E como observado na Figura 3, as arquiteturas tridimensionais (3D) foram predominantes nos estudos analisados. A explicação para isso é que as CNNs 3D permitem que o modelo analise o volume completo de TC, já que as imagens são naturalmente tridimensionais, capturando relações espaciais entre os *voxels*, que são *pixels 3D*. Essa abordagem é fundamental para a detecção precisa de nódulos, pois muitos indícios clínicos

só aparecem quando se considera a estrutura tridimensional, como foi sintetizado em [Chen and Xie 2024].

## **Q2 - Por quais motivos são utilizadas combinações híbridas de CNNs com outras arquiteturas ou abordagens?**

Apesar de seu sucesso, as CNNs apresentam algumas limitações, como, por exemplo, a dependência de grandes volumes de dados rotulados e a dificuldade em capturar relações espaciais. Tal cenário tem motivado a adoção de outras arquiteturas e abordagens alternativas com o objetivo de contornar essas restrições, como a integração com outras técnicas nas CNNs, entre elas: *CapsNet*, *Transformers*, mecanismos de atenção, aprendizado semi-supervisionado e métodos tradicionais de *Machine Learning* (ML). Essas abordagens visam aumentar a capacidade de generalização dos modelos, melhorar a interpretação das características aprendidas e reduzir a dependência de dados anotados. A Tabela 5 mostra o uso dessas abordagens.

**Tabela 5. Estudos com arquiteturas híbridas ou alternativas às CNNs tradicionais.**

<b>ID</b>	<b>Justificativa</b>
A01	Combinação de <i>features</i> manuais com 3D CNN.
A02	Uso de <i>Capsule Networks</i> + 3D CNN.
A03	CNN + <i>dual attention</i> → levemente híbrido.
A04	Combina <i>Boosting</i> + <i>ResNet-50</i> , é um modelo híbrido.
A06	Arquitetura personalizada multiescala (híbrida por <i>design</i> ).
A07	Mistura técnicas de <i>Machine Learning</i> tradicional + <i>ResNet</i> .
A12	Propõe uma CNN aprimorada com mecanismo de atenção utilizando <i>SE-Block</i> , o que caracteriza uma abordagem híbrida com foco na redução de falsos positivos.
A14	Combina atenção + <i>ResNet</i> + <i>Faster R-CNN 3D</i> → híbrido.
A15	Redes em cascata + <i>U-Net</i> → arquitetura híbrida.
A16	Combina aprendizado semi-supervisionado + <i>Expectation-maximization</i> + 3D CNN.
A17	Envolve múltiplos cenários com <i>pooling</i> personalizado (4MC) → estrutura composta.
A18	Uso de <i>Faster R-CNN</i> + <i>MSM-CNN</i> → múltiplas arquiteturas.
A19	Usa <i>transfer learning</i> + 3D <i>U-Net</i> multiescala.
A20	Incorpora <i>residual connections</i> → variação híbrida de <i>U-Net</i> .
A21	<i>Transformer</i> + aprendizado contrastivo + <i>backbone ResNet3D</i> .
A23	Combinação de <i>InceptionNeXt</i> + Atenção + <i>ResNet3D</i> → híbrido.

Na comparação entre as abordagens de CNNs puras e híbridas, observou-se que as arquiteturas híbridas geralmente apresentaram melhor desempenho do que as CNNs puras. Embora eficazes na extração automática de características das imagens, as CNNs puras demonstraram limitações quando aplicadas isoladamente, especialmente em cenários com alta variabilidade nos padrões dos nódulos pulmonares.

## **Q3 - Quais bases de dados foram utilizadas para essa tarefa?**

Como peça fundamental, o conjunto de dados define a qualidade das amostras para os trabalhos selecionados, sendo de extrema importância para esta RSL. Durante a

pesquisa, foram encontradas 7 bases de dados, das quais quatro se destacaram das demais pela frequência com que aparecem nos trabalhos analisados. A Tabela 6 mostra quais são essas bases e quantas vezes foram utilizadas nos estudos selecionados para compor a fonte de dados desta RSL.

**Tabela 6. Bases de dados utilizadas.**

<b>Base de dados</b>	<b>Quantidade de vezes que foram utilizadas</b>
LUNA16	15
LIDC-IDRI	7
TIANCHI	2
LUNGx	2
ELCAP	1
DATA SCIENCE BOWL 2017	1
NLST	1

Compondo a maioria dos artigos analisados, com um total de 888 exames de TC incluídos, o LUNA16 [Setio et al. 2017] é um desafio que apresenta uma estrutura de avaliação objetiva para algoritmos de detecção automática de nódulos, utilizando o maior banco de dados de TC, o conjunto LIDC-IDRI [Armato III et al. 2011].

O LIDC-IDRI também está presente em uma parte significativa dos trabalhos. A base oferece um conjunto robusto de tomografias computadorizadas, com cerca de 245.000 imagens, que incluem informações sobre sutileza, estrutura interna, calcificação, esfericidade, textura e malignidade, sendo uma fonte consolidada para a coleta de dados.

A LUNGx [Kirby et al. 2016] também é um desafio utilizado para a classificação computadorizada de nódulos pulmonares em TC. O conjunto de teste contém 73 nódulos pulmonares, sendo 37 benignos e 36 malignos, enquanto o conjunto de calibração contém 10 nódulos, 5 benignos e 5 malignos, utilizados para diagnóstico e avaliação do desempenho dos métodos computadorizados dos participantes.

O TIANCHI<sup>7</sup> é a base de dados de uma competição de Inteligência Artificial (IA) médica, contém 800 amostras que foram rotulados por radiologistas, com objetivo de detecção precoce e o diagnóstico inteligente do câncer de pulmão, com foco especial na identificação de pequenos nódulos pulmonares em TC.

A escolha do conjunto de dados influenciou significativamente os resultados reportados nos estudos, pois, como mencionado anteriormente, o uso de CNNs implica uma alta dependência de grandes volumes de dados rotulados, e as bases utilizadas atendem a esses requisitos. Observou-se também que as bases de dados abertas, por serem acessíveis aos pesquisadores, colaboraram mais nesse aspecto, resultando em um fluxo maior de trabalhos a serem compartilhados e comparados por meio das diversas metodologias e abordagens que podem ser aplicadas nessas bases, contribuindo ainda mais para o avanço do campo de estudo.

---

<sup>7</sup><https://tianchi.aliyun.com/competition/entrance/231601>

## 4. Conclusão

O seguinte trabalho propôs uma Revisão Sistemática da Literatura para analisar o uso de CNNs na detecção de nódulos pulmonares em imagens de TC, respondendo às suas principais questões e consolidando um panorama atualizado dos últimos cinco anos. O objetivo foi entender quais arquiteturas de CNNs e quais bases de dados públicas são mais relevantes na área, com ênfase nas abordagens 3D, que superam as limitações dos métodos 2D, assim como nas abordagens CNNs híbridas ou ajustadas e modelos pré-treinados. Destaca-se também a contribuição ativa da base LIDC-IDRI, tanto individualmente quanto por meio da base LUNA16, como principal base para essa tarefa.

Entretanto, é importante destacar algumas limitações da RSL, que foram dadas mediante a aplicação dos critérios de inclusão e exclusão, como o de acesso aberto, pode ter limitado a diversidade de abordagens e a representatividade de estudos relevantes, uma vez que alguns artigos de alto impacto estão sob acesso restrito. Além disso, a seleção por idioma, restrita ao inglês, pode ter excluído contribuições significativas em outros idiomas.

Durante a pesquisa, foi possível observar alguns desafios recorrentes na área, como a escassez de dados rotulados e de anotações clínicas detalhadas nas bases, o que pode limitar o potencial das CNNs. Cabe destacar também as dificuldades de generalização, que ocorrem por diversas razões, sendo o *overfitting* uma delas, caracterizado pela incapacidade do modelo de apresentar um bom desempenho quando testado com novos dados.

Para estudos futuros, espera-se explorar técnicas como a classificação e segmentação de nódulos pulmonares.

## Referências

- Armato III, S. G., McLennan, G., Bidaut, L., McNitt-Gray, M. F., Meyer, C. R., Reeves, A. P., Zhao, B., Aberle, D. R., Henschke, C. I., Hoffman, E. A., et al. (2011). The lung image database consortium (lidc) and image database resource initiative (idri): a completed reference database of lung nodules on ct scans. *Medical physics*, 38(2):915–931.
- Chen, Y. and Xie, M. (2024). Improved focus on hard samples for lung nodule detection. In *Proceedings of the 2024 6th International Conference on Control and Computer Vision*, pages 21–26.
- Dolejši, M. (2007). *Detection of pulmonary nodules from ct scans*. PhD thesis, Citeseer.
- Eun, H., Kim, D., Jung, C., and Kim, C. (2018). Single-view 2d cnns with fully automatic non-nodule categorization for false positive reduction in pulmonary nodule detection. *Computer methods and programs in biomedicine*, 165:215–224.
- Guimarães, N. S., Ferreira, A. J., Silva, R. d. C. R., de Paula, A. A., Lisboa, C. S., Magno, L., Ichiara, M. Y., and Barreto, M. L. (2022). Deduplicating records in systematic reviews: there are free, accurate automated ways to do so. *Journal of Clinical Epidemiology*, 152:110–115.

- Jiang, H., Ma, H., Qian, W., Gao, M., and Li, Y. (2018). An automatic detection system of lung nodule based on multigroup patch-based deep learning network. *IEEE Journal of Biomedical and Health Informatics*, 22:1227–1237.
- Johnson, N. and Phillips, M. (2018). Rayyan for systematic reviews. *Journal of Electronic Resources Librarianship*, 30(1):46–48.
- Kamiya, H., Murayama, S., Kakinohana, Y., and Miyara, T. (2011). Pulmonary nodules: a quantitative method of diagnosis by evaluating nodule perimeter difference to approximate oval using three-dimensional ct images. *Clinical Imaging*, 35(2):123–126.
- Kirby, J. S., Armato, S. G., Drukker, K., Li, F., Hadjiiski, L., Tourassi, G. D., Clarke, L. P., Engelmann, R. M., Giger, M. L., Redmond, G., and Farahani, K. (2016). LUNGx Challenge for computerized lung nodule classification. *Journal of Medical Imaging*, 3(4):044506.
- Kitchenham, B. (2004). Procedures for performing systematic reviews. *Keele, UK, Keele University*, 33(2004):1–26.
- Kitchenham, B. A. and Charters, S. (2007). Guidelines for performing systematic literature reviews in software engineering. Technical Report EBSE 2007-001, Keele University and Durham University Joint Report.
- LeCun, Y., Bottou, L., Bengio, Y., and Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11):2278–2324.
- Li, Z., Liu, F., Yang, W., Peng, S., and Zhou, J. (2021). A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE transactions on neural networks and learning systems*, 33(12):6999–7019.
- McKeown, S. and Mir, Z. M. (2021). Considerations for conducting systematic reviews: evaluating the performance of different methods for de-duplicating references. *Systematic Reviews*, 10(1):38.
- Scannavino, K. R. F., Nakagawa, E. Y., Fabbri, S. C. P. F., and Ferrari, F. C. (2017). *Revisão Sistemática da Literatura em Engenharia de Software: teoria e prática*. Elsevier.
- Setio, A. A. A., Traverso, A., De Bel, T., Berens, M. S., Van Den Bogaard, C., Cerello, P., Chen, H., Dou, Q., Fantacci, M. E., Geurts, B., et al. (2017). Validation, comparison, and combination of algorithms for automatic detection of pulmonary nodules in computed tomography images: the luna16 challenge. *Medical image analysis*, 42:1–13.
- Silva, A. C., Carvalho, P. C. P., and Gattass, M. (2005). Diagnosis of lung nodule using semivariogram and geometric measures in computerized tomography images. *Computer Methods and Programs in Biomedicine*, 79(1):31–38.
- Xie, H., Yang, D., Sun, N., Chen, Z., and Zhang, Y. (2019). Automated pulmonary nodule detection in ct images using deep convolutional neural networks. *Pattern Recognit.*, 85:109–119.
- Yan, X., Pang, J., Qi, H., Zhu, Y., Bai, C., Geng, X., Liu, M., Terzopoulos, D., and Ding, X. (2016). Classification of lung nodule malignancy risk on computed tomography images using convolutional neural network: A comparison between 2d and 3d strategies. In *Computer Vision – ACCV 2016 Workshops*. Springer International Publishing.