



Identifikasi Penyakit Tuberkulosis pada Citra X-Ray Paru Menggunakan Swin Transformer dengan Pendekatan Out-of-Distribution Detection

INFO PENPULIS	INFO ARTIKEL
Andi Citra Ayu Lestari Universitas Muhammadiyah Makassar 105841101722@student.unismuh.ac.id Desi Anggreani Universitas Muhammadiyah Makassar desiaggreani@unismuh.ac.id Muhammad Faisal Universitas Muhammadiyah Makassar muhfaisal@unismuh.ac.id Chyquitha Danuputri Universitas Muhammadiyah Makassar chyquithadanuputri@unismuh.ac.id	ISSN: 3026-3603 Vol. 4, No. 1 April 2026 http://jurnal.ardenjaya.com/index.php/ajst

© 2026 Arden Jaya Publisher All rights reserved

Saran Penulisan Referensi:

Lestari, A. C. A., Anggreani, D., Faisal, M., & Danuputri, C. (2026). Identifikasi Penyakit Tuberkulosis pada Citra X-Ray Paru Menggunakan Swin Transformer dengan Pendekatan Out-of-Distribution Detection. *Arus Jurnal Sains dan Teknologi*, 4 (1), 124-131.

Abstrak

Penelitian ini bertujuan mengimplementasikan arsitektur *Swin Transformer* untuk mengidentifikasi penyakit tuberkulosis pada citra X-Ray paru serta mengevaluasi kemampuan pendekatan *Out-of-Distribution Detection* dalam mengenali citra yang tidak sesuai dengan distribusi data pelatihan. Data penelitian terdiri atas 1.272 citra yang terbagi seimbang ke dalam tiga kelas, yaitu Tuberkulosis, Non-Tuberkulosis, dan Tidak Dikenali/*Out-of-Distribution Detection*. Tahapan penelitian meliputi seleksi kualitas citra, *resize* ke ukuran 384 x 384 piksel, *augmentasi* data latih, pelatihan model *Swin Transformer*, serta evaluasi menggunakan *accuracy*, *macro F1-score*, *confusion matrix*, dan *AUC*. Hasil penelitian menunjukkan bahwa model *Swin Transformer* tunggal memperoleh *accuracy* 83,59% dan *macro F1-score* 83,59% pada klasifikasi Tuberkulosis dan Non-Tuberkulosis. Model Hybrid *Swin Transformer* + *Out-of-Distribution Detection* menghasilkan kinerja lebih baik dengan *accuracy* 89,06%, *macro F1-score* 89,10%, dan *Out-of-Distribution Detection Rate* 98,44%. Temuan ini menunjukkan bahwa integrasi *Out-of-Distribution Detection* mampu meningkatkan keandalan sistem karena model tidak memaksakan prediksi terhadap citra yang tidak relevan. Sistem yang dikembangkan dapat digunakan sebagai alat bantu skrining awal, dengan keputusan akhir tetap berada pada tenaga medis.

Kata Kunci: Tuberkulosis; Citra X-Ray; Swin Transformer; Out-of-Distribution Detection; Deep Learning

Abstract

This study aims to implement the Swin Transformer architecture for tuberculosis identification on chest X-ray images and evaluate the capability of an Out-of-Distribution Detection approach to recognize images that do not match the training data distribution. The dataset consisted of 1,272 images distributed evenly into three classes: Tuberculosis, Non-Tuberculosis, and Unknown/Out-of-Distribution Detection. The research stages included image quality selection, resizing to 384 x 384 pixels, training-data augmentation, Swin Transformer training, and evaluation using accuracy, macro F1-score, confusion matrix, and AUC. The baseline Swin Transformer model achieved 83.59% accuracy and 83.59% macro F1-score for Tuberculosis and Non-Tuberculosis classification. The Hybrid Swin Transformer + Out-of-Distribution Detection model achieved better performance, with 89.06% accuracy, 89.10% macro F1-score, and 98.44% Out-of-Distribution Detection Rate. These findings indicate that integrating Out-of-Distribution Detection improves system reliability by preventing forced predictions on irrelevant images. The developed system can support early screening, while final clinical decisions remain under medical authority.

Keywords: Tuberculosis; Chest X-Ray; Swin Transformer; Out-of-Distribution Detection; Deep Learning

A. Pendahuluan

Tuberkulosis masih menjadi masalah kesehatan global yang memerlukan deteksi dini, konsisten, dan mudah diterapkan pada layanan kesehatan. Laporan Global Tuberculosis Report 2024 menempatkan tuberkulosis sebagai salah satu penyebab utama kematian akibat penyakit menular, dengan beban kasus yang masih tinggi di negara berkembang, termasuk Indonesia (WHO, 2024). Kondisi ini memperlihatkan bahwa strategi skrining berbasis teknologi perlu diperkuat agar proses identifikasi kasus dapat dilakukan lebih cepat dan dapat menjangkau wilayah dengan keterbatasan tenaga ahli.

Radiografi dada atau citra X-Ray paru banyak digunakan sebagai modalitas skrining awal karena relatif terjangkau, cepat, dan tersedia di berbagai fasilitas pelayanan kesehatan. Walaupun demikian, interpretasi citra X-Ray paru tidak selalu sederhana karena gambaran tuberkulosis dapat muncul dalam bentuk infiltrat, opasitas, kavitas, atau perubahan struktur paru yang tidak seragam. Variasi kualitas citra, posisi pasien, serta pengalaman pemeriksa dapat memengaruhi konsistensi hasil pembacaan, sehingga sistem berbasis kecerdasan buatan berpotensi menjadi alat bantu yang objektif (Showkatian et al., 2022; Yayan et al., 2024).

Perkembangan *deep learning* telah membuka peluang baru dalam analisis citra medis. Model Convolutional Neural Network telah banyak digunakan untuk klasifikasi citra, tetapi arsitektur ini memiliki keterbatasan pada receptive field lokal sehingga kurang optimal dalam menangkap hubungan spasial jarak jauh. Pada citra X-Ray paru, pola tuberkulosis tidak selalu berada pada satu area yang jelas, sehingga model perlu memahami relasi lokal dan global secara bersamaan (Takahashi et al., 2024; Xia et al., 2025).

Swin Transformer menawarkan pendekatan yang relevan untuk kebutuhan tersebut melalui mekanisme *shifted window attention* dan representasi hierarkis. Arsitektur ini memungkinkan model memproses citra beresolusi tinggi secara lebih efisien dibanding Vision Transformer standar, sekaligus tetap mempertahankan kemampuan mempelajari konteks global. Keunggulan ini menjadikan *Swin Transformer* banyak digunakan dalam tugas klasifikasi dan segmentasi citra medis, termasuk citra toraks (Liu et al., 2021; Rana et al., 2025; Visu et al., 2025).

Masalah penting yang sering luput dalam sistem klasifikasi medis adalah ketahanan model terhadap data yang berada di luar distribusi pelatihan. Model *deep learning* konvensional dapat memberikan prediksi dengan tingkat keyakinan tinggi meskipun citra yang dimasukkan bukan citra X-Ray paru atau memiliki karakteristik yang berbeda dari data latih. Fenomena *overconfidence* ini berisiko menimbulkan keputusan yang tidak dapat dipertanggungjawabkan secara klinis. Oleh karena itu, *Out-of-Distribution Detection* diperlukan agar sistem mampu menolak citra tidak relevan dan tidak memaksakan prediksi ke kelas Tuberkulosis atau Non-Tuberkulosis (Cui & Wang, 2022; Hong et al., 2024; Wollek et al., 2024).

Penelitian ini berfokus pada identifikasi tuberkulosis pada citra X-Ray paru menggunakan *Swin Transformer* yang dikombinasikan dengan pendekatan *Out-of-Distribution Detection*.

Kontribusi utama penelitian terletak pada pengujian dua skenario model, yaitu *Swin Transformer* sebagai *baseline* klasifikasi biner dan *Hybrid Swin Transformer + Out-of-Distribution Detection* sebagai model tiga kelas. Perbandingan tersebut digunakan untuk menilai apakah penambahan mekanisme deteksi data asing mampu meningkatkan performa dan keamanan sistem pada skenario penggunaan yang lebih realistis.

B. Metodologi


Penelitian ini menggunakan pendekatan eksperimen kuantitatif berbasis *deep learning*. Objek penelitian berupa citra X-Ray paru yang digunakan untuk membangun sistem klasifikasi Tuberkulosis, Non-Tuberkulosis, dan *Out-of-Distribution Detection*. Data utama penelitian berasal dari data citra X-Ray paru yang dikembangkan dalam skripsi, sedangkan kelas *Out-of-Distribution Detection* digunakan untuk menguji kemampuan sistem dalam mengenali input yang tidak sesuai dengan distribusi data pelatihan.

Tahapan penelitian dimulai dari pengumpulan data, seleksi kualitas citra, *preprocessing*, *augmentasi* data latih, pembagian dataset, pelatihan model, evaluasi performa, dan *inference* pada citra baru. Seluruh citra diubah ke ukuran 384 x 384 piksel agar sesuai dengan kebutuhan *backbone Swin Transformer* yang digunakan. Pada data latih diterapkan *augmentasi* ringan, seperti rotasi kecil, pergeseran posisi, serta penyesuaian brightness dan contrast, agar model lebih tahan terhadap variasi teknis pengambilan citra.

Dataset dibagi menggunakan rasio 70:15:15 untuk *training*, *validation*, dan *testing*. Pembagian dilakukan secara seimbang agar proporsi kelas tetap adil pada setiap subset. Pada skenario *baseline*, model hanya menggunakan dua kelas *in-distribution*, yaitu Non-Tuberkulosis dan Tuberkulosis. Pada skenario hybrid, model menggunakan tiga kelas, yaitu Non-Tuberkulosis, Tuberkulosis, dan *Out-of-Distribution Detection*.

Model yang digunakan adalah *Swin Transformer* dengan *backbone* *swin_base_patch4_window12_384*. Model *baseline* memiliki dua kelas keluaran, sedangkan model hybrid memiliki tiga kelas keluaran. Penambahan kelas *Out-of-Distribution Detection* dilakukan dengan pendekatan *outlier exposure*, yaitu memperkenalkan contoh citra yang tidak termasuk distribusi utama agar model belajar memberikan keputusan penolakan terhadap input tidak relevan.

Evaluasi dilakukan menggunakan beberapa metrik agar performa model tidak hanya dilihat dari *accuracy*. Metrik utama yang digunakan meliputi *accuracy*, *macro F1-score*, *confusion matrix*, *AUC*, dan *Out-of-Distribution Detection Rate*. *Accuracy* digunakan untuk menilai proporsi prediksi benar, *macro F1-score* digunakan untuk melihat keseimbangan performa antar kelas, *AUC* digunakan untuk menilai kemampuan separasi kelas, sedangkan *Out-of-Distribution Detection Rate* digunakan untuk mengukur kemampuan sistem mengenali citra tidak dikenali.



Gambar 1. Alur sistem identifikasi tuberkulosis berbasis Swin Transformer dan Out-of-Distribution Detection

Tabel 1. Komposisi Data Penelitian

No	Kategori Data	Jumlah Citra	Proporsi
1	Tuberkulosis	424	33%
2	Non-Tuberkulosis	424	33%
3	Tidak Dikenali/Out-of-Distribution Detection	424	33%
Total		1.272	100%

Tabel 2. Pembagian Dataset

Subset	Non-Tuberkulosis	Tuberkulosis	OOD Detection	Total	Persentase
Training	296	296	296	888	69,81%
Validasi	64	64	64	192	15,09%
Pengujian	64	64	64	192	15,09%
Total	424	424	424	1.272	100%

Tabel 3. Skenario Model yang Digunakan

Skenario Model	Jumlah Kelas	Kelas Keluaran	Fungsi Utama
Swin Transformer	2 kelas	Non-Tuberkulosis; Tuberkulosis	Baseline klasifikasi citra X-Ray paru
Swin Transformer + Out-of-Distribution Detection	3 kelas	Non-Tuberkulosis; Tuberkulosis; Out-of-Distribution Detection	Klasifikasi dan deteksi citra di luar distribusi

Tabel 4. Konfigurasi Hyperparameter Utama

Hyperparameter	Nilai	Keterangan
Batch Size	4	Mini-batch per iterasi
Epochs	50	Maksimum epoch pelatihan
Learning Rate	1×10^{-4}	Laju pembelajaran awal AdamW
Weight Decay	1×10^{-4}	Regularisasi L2 pada optimizer
Label Smoothing	0,05	Regularisasi distribusi target label
Patience	12	Toleransi early stopping
Accumulation Steps	4	Effective batch size = 16
Dropout Rate	0,4	Regularisasi pada classifier
Ukuran Input Citra	384 x 384 piksel	Sesuai backbone Swin Transformer

C. Hasil dan Pembahasan

Hasil pengujian menunjukkan bahwa *Swin Transformer* mampu membedakan citra Tuberkulosis dan Non-Tuberkulosis dengan performa yang cukup baik pada data *in-distribution*. Pada skenario *baseline*, dari 128 citra uji yang terdiri atas 64 citra Non-Tuberkulosis dan 64 citra Tuberkulosis, model berhasil memprediksi 107 citra dengan benar. Nilai *accuracy* dan *macro F1-score* yang diperoleh sama-sama sebesar 83,59%.

Kelemahan utama model *baseline* terlihat ketika sistem berhadapan dengan citra *Out-of-Distribution Detection*. Karena model hanya memiliki dua kelas keluaran, seluruh citra asing dipaksa masuk ke kelas Non-Tuberkulosis atau Tuberkulosis. Kondisi ini menguatkan alasan bahwa akurasi klasifikasi biner tidak cukup untuk menjamin keamanan sistem kecerdasan buatan medis pada kondisi lapangan yang tidak sepenuhnya terkontrol.

Model Hybrid *Swin Transformer + Out-of-Distribution Detection* menunjukkan performa yang lebih kuat. Dari 192 citra uji, model berhasil mengklasifikasikan 171 citra dengan benar dan memperoleh *accuracy* 89,06% serta *macro F1-score* 89,10%. Pada kelas *Out-of-Distribution Detection*, 63 dari 64 citra berhasil dikenali sebagai citra tidak dikenali, sehingga *Out-of-Distribution Detection Rate* mencapai 98,44%. Hasil ini menunjukkan bahwa penambahan kelas OOD tidak hanya memberi kemampuan penolakan terhadap citra asing, tetapi juga tetap mempertahankan performa klasifikasi utama.

Tabel 5. Confusion Matrix Model Swin Transformer Baseline


Kelas	TP	TN	FP	FN
Non-Tuberkulosis	54	53	11	10
Tuberkulosis	53	54	10	11

Tabel 6. Confusion Matrix Model Hybrid Swin Transformer + OOD Detection

Kelas	TP	TN	FP	FN
Non-Tuberkulosis	55	116	12	9
Tuberkulosis	53	119	9	11
Out-of-Distribution Detection	63	128	0	1

Tabel 7. Perbandingan Kinerja Model

Metrik	Swin Transformer	Swin Transformer + OOD Detection
Jumlah Kelas	2 kelas	3 kelas
Kelas yang diuji	Non-Tuberkulosis; Tuberkulosis	Non-Tuberkulosis; Tuberkulosis; OOD Detection
Jumlah Data Uji	128	192
Prediksi Benar	107	171
Accuracy	83,59%	89,06%
Macro F1-Score	83,59%	89,10%
Out-of-Distribution Detection Rate	Tidak tersedia	98,44%



Gambar 2. Perbandingan accuracy dan macro F1-score model

Jika dilihat dari metrik *AUC*, model hybrid juga menunjukkan kemampuan separasi kelas yang kuat. Nilai *AUC* untuk kelas Non-Tuberkulosis mencapai 0,960, kelas Tuberkulosis 0,962, dan kelas *Out-of-Distribution Detection* 1,000. Nilai *AUC* yang mendekati satu menunjukkan bahwa model memiliki kemampuan diskriminasi yang baik dalam membedakan setiap kelas pada data uji.

Hasil ini sejalan dengan argumentasi teoritis bahwa *Swin Transformer* mampu menggabungkan informasi lokal dan global melalui mekanisme attention yang hierarkis. Pada citra X-Ray paru, kemampuan ini penting karena tanda tuberkulosis dapat berupa pola visual yang menyebar, tidak selalu simetris, dan tidak selalu tampak sebagai lesi lokal yang jelas. Dibanding model yang hanya mengandalkan pola lokal, struktur *Swin Transformer* lebih sesuai untuk membaca konteks citra toraks secara menyeluruh.

Dari sisi keandalan sistem, kontribusi paling penting terdapat pada mekanisme *Out-of-Distribution Detection*. Sistem diagnosis berbasis AI tidak boleh hanya mengejar *accuracy* tinggi pada data yang mirip dengan data latih. Sistem juga harus dapat mengenali situasi ketika input berada di luar batas pengetahuan model. Pada penelitian ini, kemampuan menolak 63 dari 64 citra OOD menunjukkan bahwa sistem lebih aman dibanding model *baseline* karena tidak memaksakan keputusan medis pada citra yang tidak relevan.

Waktu *inference* rata-rata sebesar 0,1672 detik per citra memperlihatkan bahwa sistem berjalan cepat untuk skenario skrining awal. Waktu tercepat tercatat 0,0484 detik dan waktu terlama 0,2931 detik. Kecepatan ini berpotensi membantu proses kerja radiologi, terutama pada situasi jumlah pemeriksaan tinggi. Walaupun demikian, hasil sistem tetap perlu ditempatkan sebagai second opinion atau alat bantu awal, bukan sebagai pengganti pemeriksaan dokter.

Secara praktis, penggunaan *threshold* berlapis pada tahap *inference* membuat sistem lebih hati-hati. Citra dengan probabilitas OOD tinggi ditolak sebagai *Out-of-Distribution Detection*. Citra dengan probabilitas Tuberkulosis melebihi ambang batas dikategorikan sebagai suspek

Tuberkulosis, sedangkan citra Non-Tuberkulosis hanya diterima ketika probabilitasnya sangat kuat dan probabilitas Tuberkulosis rendah. Strategi ini mengurangi risiko sistem terlalu mudah menyatakan citra sebagai Non-Tuberkulosis ketika masih terdapat indikasi penyakit.

Tabel 8. Nilai AUC pada Tiap Kelas

No	Kelas	Nilai AUC
1	Non-Tuberkulosis	0,960
2	Tuberkulosis	0,962
3	Out-of-Distribution Detection	1,000

Tabel 9. Logika Keputusan Sistem Inference

No	Kondisi Probabilitas	Keputusan Sistem
1	$P(\text{Out-of-Distribution Detection}) \geq 0,50$	Ditolak / Out-of-Distribution Detection
2	$P(\text{Tuberkulosis}) \geq 0,35$	Diterima - Suspek Tuberkulosis
3	$P(\text{Non-Tuberkulosis}) \geq 0,85$ dan $P(\text{Tuberkulosis}) < 0,35$	Diterima - Non-Tuberkulosis
4	Selisih probabilitas Non-Tuberkulosis dan Tuberkulosis kecil	Perlu review / tidak yakin

D. Kesimpulan

Penelitian ini berhasil mengimplementasikan arsitektur *Swin Transformer* untuk mengidentifikasi penyakit tuberkulosis pada citra X-Ray paru. Model *baseline Swin Transformer* mampu melakukan klasifikasi dua kelas, yaitu Tuberkulosis dan Non-Tuberkulosis, dengan *accuracy* 83,59% dan *macro F1-score* 83,59%. Hasil tersebut menunjukkan bahwa arsitektur *Swin Transformer* dapat mempelajari pola visual citra X-Ray paru secara cukup baik.

Penambahan pendekatan *Out-of-Distribution Detection* meningkatkan keandalan sistem. Model Hybrid *Swin Transformer + Out-of-Distribution Detection* menghasilkan *accuracy* 89,06%, *macro F1-score* 89,10%, dan *Out-of-Distribution Detection Rate* 98,44%. Dari 192 citra uji, sebanyak 171 citra berhasil diprediksi dengan benar, sedangkan 63 dari 64 citra OOD berhasil dikenali sebagai citra tidak dikenali.

Secara keseluruhan, integrasi *Swin Transformer* dan *Out-of-Distribution Detection* memberikan model yang lebih aman untuk skenario skrining awal karena sistem tidak hanya mengklasifikasikan citra medis, tetapi juga mampu menolak input yang tidak sesuai distribusi. Penelitian selanjutnya perlu menggunakan dataset yang lebih besar, berasal dari beberapa institusi, serta membandingkan metode OOD lain agar kemampuan generalisasi dan keamanan sistem dapat diuji secara lebih luas.

E. Referensi

- Ahmad, K., Rehman, H. U., Shah, B., Ali, F., & Hussain, I. (2025). Dual-model approach for accurate chest disease detection using GViT and Swin Transformer V2. *Scientific Reports*, 15(1), 1-22. <https://doi.org/10.1038/s41598-025-16422-6>
- Alsayed, S. S. R., & Gunosewoyo, H. (2023). Tuberculosis: Pathogenesis, current treatment regimens and new drug targets. *International Journal of Molecular Sciences*, 24(6). <https://doi.org/10.3390/ijms24065202>
- Archana, R., & Jeevaraj, P. S. E. (2024). Deep learning models for digital image processing: A review. *Artificial Intelligence Review*, 57(1). <https://doi.org/10.1007/s10462-023-10631-z>
- Cui, P., & Wang, J. (2022). Out-of-distribution detection based on deep learning: A review. *Electronics*, 11(21), 1-19. <https://doi.org/10.3390/electronics11213500>
- El-Ghany, S. A., Elmogy, M., Mahmood, M. A., & Abd El-Aziz, A. A. (2024). A robust tuberculosis diagnosis using chest X-rays based on a hybrid Vision Transformer and principal component analysis. *Diagnostics*, 14(23). <https://doi.org/10.3390/diagnostics14232736>

- Hong, Z., Yue, Y., Chen, Y., Cong, L., Lin, H., Luo, Y., Wang, M. H., Wang, W., Xu, J., Yang, X., Chen, H., Li, Z., & Xie, S. (2024). Out-of-distribution detection in medical image analysis: A survey. arXiv. <http://arxiv.org/abs/2404.18279>
- Jiang, W., Zhang, H., Li, Z., Jiang, X., Shao, J., Yang, X., Xiong, J., Zhou, P., Zhang, H., Wang, H., Yu, J., Su, X., Wang, Y., Liu, J., & Li, Z. (2025). AI-powered chest X-ray for diagnosing pulmonary tuberculosis in county and township health care facilities in Yichang: Retrospective, real-world study. *Journal of Medical Internet Research*, 27, e83041. <https://doi.org/10.2196/83041>
- Karimi, F., Farnia, F., & Bae, K. T. (2025). Robust detection of out-of-distribution shifts in chest X-ray imaging. *Journal of Imaging Informatics in Medicine*. <https://doi.org/10.1007/s10278-025-01559-7>
- Lestari, T., Fuady, A., Yani, F. F., Putra, I. W. G. A. E., Pradipta, I. S., Chaidir, L., Handayani, D., Fitriangga, A., Loprang, M. R., Pambudi, I., Ruslami, R., & Probandari, A. (2023). The development of the national tuberculosis research priority in Indonesia: A comprehensive mixed-method approach. *PLoS ONE*, 18(2), 1-14. <https://doi.org/10.1371/journal.pone.0281591>
- Liu, Z., Lin, Y., Cao, Y., Hu, H., Wei, Y., Zhang, Z., Lin, S., & Guo, B. (2021). Swin Transformer: Hierarchical Vision Transformer using shifted windows. *Proceedings of the IEEE International Conference on Computer Vision*, 9992-10002. <https://doi.org/10.1109/ICCV48922.2021.00986>
- Mahajaya, N. S., Ayu, P. D. W., & Huizen, R. R. (2024). Classification of lung diseases in X-ray images using transformer-based deep learning models. *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, 13(3), 494-505. <https://doi.org/10.23887/janapati.v13i3.81425>
- Oloko-Oba, M., & Viriri, S. (2022). A systematic review of deep learning techniques for tuberculosis detection from chest radiograph. *Frontiers in Medicine*, 9, 1-11. <https://doi.org/10.3389/fmed.2022.830515>
- Pu, Q., Xi, Z., Yin, S., Zhao, Z., & Zhao, L. (2024). Advantages of transformer and its application for medical image segmentation: A survey. *BioMedical Engineering Online*, 23(1), 1-22. <https://doi.org/10.1186/s12938-024-01212-4>
- Rana, N., Coulibaly, Y., Noor, A., Noor, T. H., Alam, M. I., Khan, Z., Tahir, A., & Khan, M. Z. (2025). Improved Swin Transformer-based thorax disease classification with optimal feature selection using chest X-ray. *PLoS ONE*, 20(6), e0327099. <https://doi.org/10.1371/journal.pone.0327099>
- Showkatian, E., Salehi, M., Ghaffari, H., Reiazi, R., & Sadighi, N. (2022). Deep learning-based automatic detection of tuberculosis disease in chest X-ray images. *Polish Journal of Radiology*, 87, e118-e124. <https://doi.org/10.5114/pjr.2022.113435>
- Takahashi, S., Sakaguchi, Y., Kouno, N., Takasawa, K., Ishizu, K., Akagi, Y., Aoyama, R., Teraya, N., Bolatkan, A., Shinkai, N., Machino, H., Kobayashi, K., Asada, K., Komatsu, M., Kaneko, S., Sugiyama, M., & Hamamoto, R. (2024). Comparison of Vision Transformers and Convolutional Neural Networks in medical image analysis: A systematic review. *Journal of Medical Systems*, 48(1), 84. <https://doi.org/10.1007/s10916-024-02105-8>
- Visu, P., Sathiya, V., Ajitha, P., & Surendran, R. (2025). Enhanced Swin Transformer based tuberculosis classification with segmentation using chest X-ray. *Journal of X-Ray Science and Technology*, 33(1), 167-186. <https://doi.org/10.1177/08953996241300018>
- WHO. (2024). Global tuberculosis report 2024. World Health Organization. <https://www.who.int/publications/i/item/9789240101531>
- Wollek, A., Willem, T., Ingrisch, M., Sabel, B., & Lasser, T. (2024). Out-of-distribution detection with in-distribution voting using the medical example of chest X-ray classification. *Medical Physics*, 51(4), 2721-2732. <https://doi.org/10.1002/mp.16790>
- Xia, Q., Zheng, H., Zou, H., Luo, D., Tang, H., Li, L., & Jiang, B. (2025). A comprehensive review of deep learning for medical image segmentation. *Neurocomputing*, 613. <https://doi.org/10.1016/j.neucom.2024.128740>

- Yayan, J., Franke, K.-J., Berger, M., Windisch, W., & Rasche, K. (2024). Early detection of tuberculosis: A systematic review. *Pneumonia*, 16(1). <https://doi.org/10.1186/s41479-024-00133-z>
- Yulvina, R., Putra, S. A., Rizkinia, M., Pujitresnani, A., Tenda, E. D., Yunus, R. E., Djumaryo, D. H., Yusuf, P. A., & Valindria, V. (2024). Hybrid Vision Transformer and Convolutional Neural Network for multi-class and multi-label classification of tuberculosis anomalies on chest X-ray. *Computers*, 13(12), 1-29. <https://doi.org/10.3390/computers13120343>
- Zhou, W., Cheng, G., Zhang, Z., Zhu, L., Jaeger, S., Lure, F. Y. M., & Guo, L. (2022). Deep learning-based pulmonary tuberculosis automated detection on chest radiography: Large-scale independent testing. *Quantitative Imaging in Medicine and Surgery*, 12(4), 2344-2355. <https://doi.org/10.21037/qims-21-676>