

Deteksi Pneumothorax pada Citra X-ray menggunakan Convolutional Neural Network

Muhammad Dimas Nugraha Aryatama, Ahmad Zaini, Reza Fuad Rachmadi

Dept. Teknik Komputer Institut Teknologi Sepuluh Nopember Surabaya, Indonesia

Email: aryatama.dimas16@mhs.te.its.ac.id, zaini@its.ac.id, fuad@its.ac.id

Abstrak

Pneumothorax adalah salah satu kondisi paru-paru dimana terkumpulnya udara yang pada rongga pleura, yaitu rongga tipis dibatasi dua selaput pleura diantara paru-paru dan dinding dada. Kondisi *Pneumothorax* termasuk kedalam kategori kondisi kritis pada paru-paru yang memerlukan penanganan medis dari dokter atau ahli medis lain dengan cepat. Jika tidak ditangani dengan cepat maka dapat menyebabkan komplikasi hingga kematian. Maka dari itu deteksi dini dari kondisi *Pneumothorax* adalah suatu hal yang perlu diprioritaskan.

Permasalahan yang sering terjadi saat ini adalah perbedaan analisis/penafsiran gambar medis antar dokter. Sementara metode diagnosis saat ini masih bersifat manual yaitu ahli radiologi perlu mengecek gambar secara langsung dengan bantuan *Computer Aided Detection and Diagnosis* (CAD). Dikarenakan tingkat akurasi prediksi dari CAD masih belum signifikan maka diperlukan teknologi *Deep Learning*. Salah satunya metode yang digunakan untuk melakukan proses training deteksi adalah menggunakan *Convolutional Neural Network*.

Untuk menjawab atas permasalahan tersebut, maka pada penelitian ini akan dikembangkan sebuah sistem yang menggunakan CNN agar dapat melakukan pendekripsi kondisi *Pneumothorax*, sehingga dapat membantu meninggalkan diagnosis yang dilakukan oleh dokter. Data citra yang digunakan adalah Dataset NIH Chest X-ray yang berjumlah 112.121 citra dan dipublikasikan oleh National Institutes of Health. Dataset tersebut terbagi menjadi tiga belas jenis penyakit paru-paru.

Kata kunci: *Pneumothorax, Deep Learning, Convolutional Neural Network*

Diterima Redaksi: 19-Nov-2024 Selesai Revisi: 1-Des-2024 Diterbitkan Online: 15-Des-2024

DOI: <https://doi.org/10.59378/jcenim.v2i3.61>

I. PENDAHULUAN

Pneumothorax adalah istilah medis untuk terkumpulnya udara pada rongga pleura, yaitu rongga tipis yang dibatasi dua selaput pleura di antara paru-paru dan dinding dada. Udara yang terkumpul pada rongga pleura dapat terjadi akibat adanya celah yang terbentuk akibat cedera pada dinding dada atau robekan pada jaringan paru-paru. Akibatnya, udara tersebut dapat menekan paru-paru dan membuat paru-paru menjadi mengempis (kolaps) [1].

Dalam sebuah survei di Minnesota, AS, kejadian *pneumothorax* adalah 7/100.000 untuk pria dan 1/100.000 untuk wanita. Di Inggris dan Wales, tingkat keseluruhan orang yang berkonsultasi dengan *pneumothorax* adalah 24/100.000 per tahun untuk pria dan 10/100.000 per tahun untuk wanita. Insiden tahunan untuk keseluruhan rawat inap darurat rumah sakit untuk *pneumothorax* di Inggris dan Wales adalah 16.7/100.000 untuk pria dan 5.8/100.000 untuk wanita. Sementara tingkat kematian dari *pneumothorax* jarang terjadi, tingkat kekambuhan terhitung tinggi dengan angka 35% [2].

X-ray dada adalah salah satu pemeriksaan radiologis yang paling umum diakses untuk skrining dan diagnosis banyak penyakit paru-paru dikarenakan harga yang terhitung relatif murah jika dibandingkan dengan alat akuisisi lain seperti CT, PET, dll, juga tidak semua institusi memiliki alat akuisisi lain terutama untuk daerah selain perkotaan besar. X-ray memiliki kekurangan dibandingkan alat akuisisi lain karena memiliki noise yang cukup banyak sehingga membuat gambar lebih sulit untuk dianalisis oleh radiografer. Di dalam institusi klinik, kemampuan untuk memprioritaskan gambar yang memiliki fitur lebih banyak dapat dilakukan dengan menggunakan label. Gambar x-ray yang didapat kemudian akan digunakan oleh dokter untuk dilakukan proses diagnosis [3].

Metode diagnosis saat ini masih menggunakan cara yang konvensional yaitu radiografer menganalisis gambar x-ray pasien secara langsung menggunakan bantuan *Computer Aided Detection and Diagnosis*

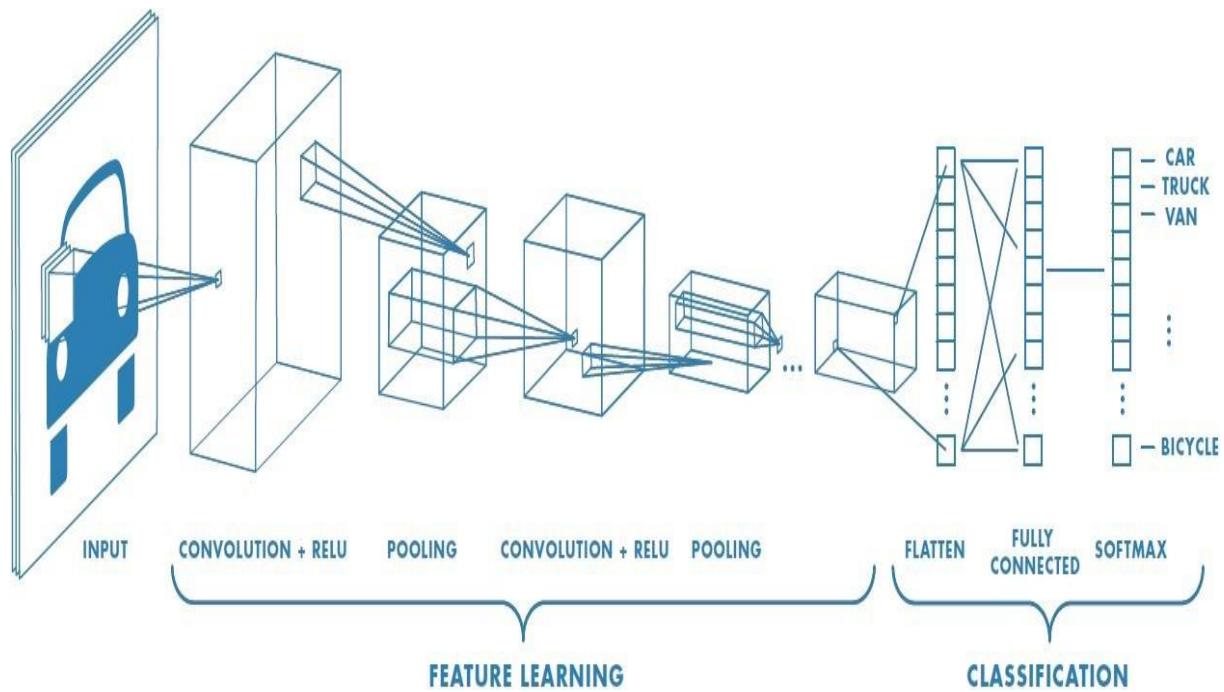
(CAD). Secara umum, dua faktor penting dalam penilaian CAD adalah populasi pasien yang menjalani pemeriksaan dan populasi dokter yang menafsirkan data gambar. Kedua hal ini telah ditemukan sebagai sumber utama variabilitas dalam interpretasi citra medis. Walaupun perbedaan dalam kasus menambah variabilitas jenis penyakit, variabilitas yang luas berpotensi besar menyimpang dari penafsiran dokter. Studi menunjukkan dari 108 mammographers di Amerika Serikat yang menggunakan CAD umum menunjukkan bahwa pembaca memiliki 40% kepekaan dan 45% dalam spesifitas [4].

Sementara masalah yang marak terjadi pada saat ini adalah penentuan gambar yang memiliki fitur medis lebih banyak juga menjadi kendala yang dialami oleh radiografer. Permasalahan ini dapat diselesaikan dengan cara menambahkan label pada gambar. Namun dengan melakukan ini dapat menimbulkan masalah baru yaitu tertumpuknya label pada suatu gambar karena memiliki banyak fitur medis. Hal ini dapat menyebabkan perbedaan dalam penafsiran/analisis pada gambar x-ray [4].

Berdasarkan permasalahan dari latar belakang di atas, maka adapun permasalahan yang dapat diamati adalah hingga saat ini masih belum ada sistem yang bisa digunakan untuk melakukan pendekatan terhadap kondisi *Pneumothorax*.

II. DESAIN SISTEM KLASIFIKASI

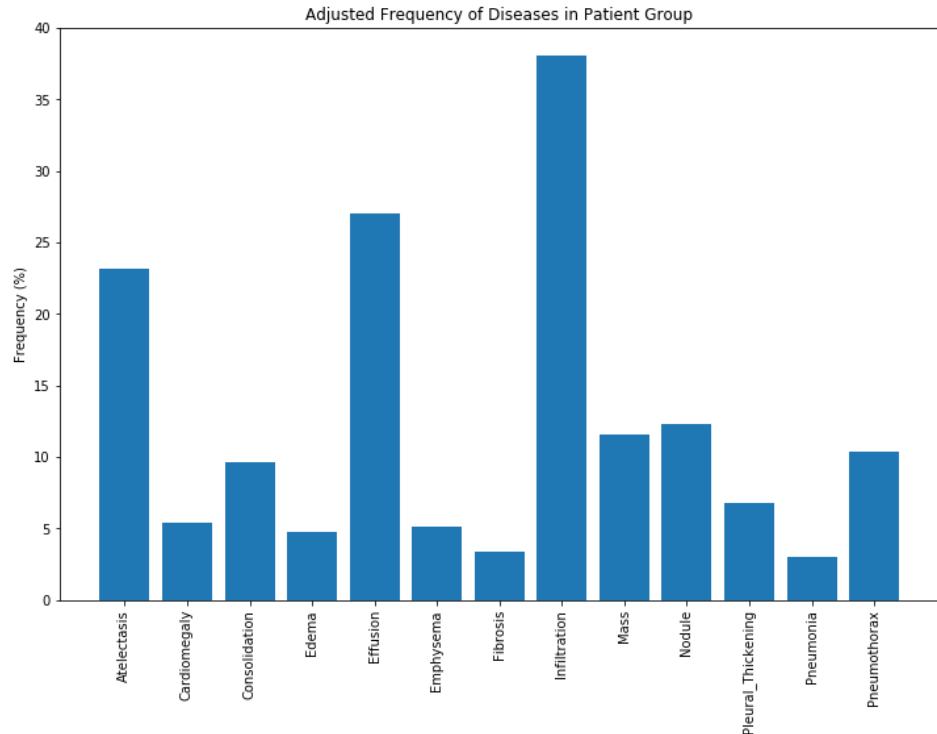
Convolutional Neural Network (CNN) adalah salah satu arsitektur jaringan yang paling umum digunakan untuk deteksi gambar. CNN berhasil digunakan dalam berbagai aplikasi mulai dari visi komputer hingga pemrosesan citra medis. Dalam makalah ini, disajikan sistem deteksi *Pneumothorax* dengan menggunakan CNN berbasis Tensorflow dan Keras. Gambar x-ray yang dimasukkan akan diproses menggunakan weight yang didapatkan setelah melakukan proses training dari dataset yang diperoleh. Arsitektur CNN umum yang menjadi pondasi dalam penelitian ini dapat dilihat pada Gambar 1.



Gambar 1: Arsitektur Convolutional Neural Network

A. Persiapan Data

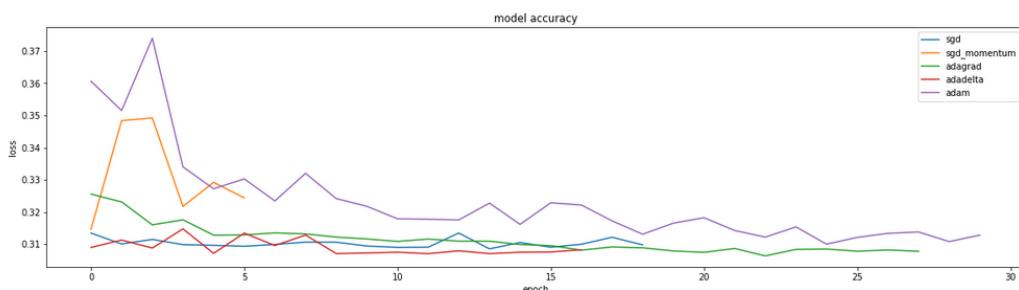
Pada Gambar 2 terpapar persentase dari dataset yang digunakan untuk pasien yang mengidap penyakit paru-paru yang sudah dipisahkan dari gambar yang tidak berpenyakit. Setelah kita pisahkan gambar yang mengidap penyakit dan tidak kita kemudian menyamaratakan jumlah data agar tidak terjadi overfitting karena banyaknya jumlah dataset untuk penyakit tertentu dibandingkan yang lain. Hasil dari pemerataan tersebut kita bagi lagi menjadi dua data untuk training dan validation berjumlah 30.000 citra untuk training dan 10.000 sisanya untuk validation.



Gambar 2: Dataset Setelah Disesuaikan

B. Pemilihan Optimizer

Pemilihan Optimizer dilakukan untuk menentukan optimizer mana yang memiliki nilai loss terkecil. Pada Gambar 3 dapat dilihat bahwa adagrad dan adadelta meraih titik konvergensi tercepat dibandingkan optimizer lain, namun jika fungsi training dilakukan dalam jumlah banyak per epoch maka adam mengungguli yang lain. Dengan hasil tersebut maka diputuskan kita akan menggunakan optimizer adam sebagai basisnya.



Gambar 3: Pemilihan Optimizer

C. Ukuran Batch dan Learning Rate

Penentuan jumlah batch size dan learning rate adalah suatu hal yang krusial untuk mendapatkan hasil dengan loss terkecil. Pada Gambar 4 terlihat bahwa perbandingan langkah akumulasi batch size ($32 \times n$) dan learning rate. Gradient step size 8 dengan ukuran 256 dan learning rate berkisar 0.00005 adalah spesifikasi dengan nilai loss terendah yang dapat dicapai oleh model dengan nilai 0.290358.

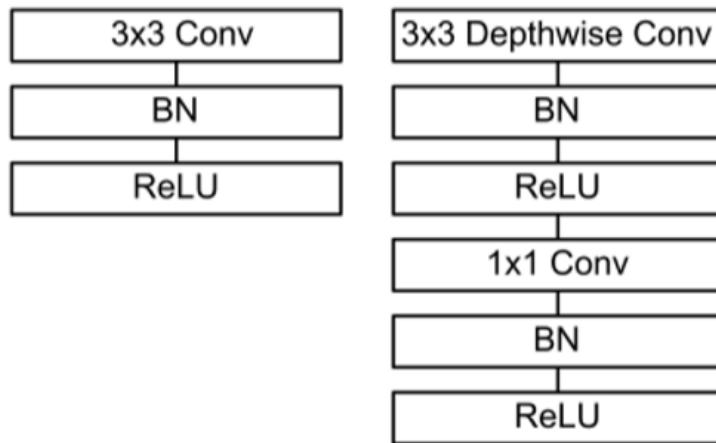
16	8	4	2	1
0.0001	0.295589	0.290940	0.291096	0.291114
0.0002	0.292183	0.290778	0.292749	0.295205
0.0005	0.292172	0.290358	0.296313	0.295768
0.0010	0.295250	0.294524	0.300698	0.305965
0.0020	0.295688	0.307935	0.305549	0.310820
0.0050	0.311269	0.317222	0.328226	0.332057
0.0100	0.322142	0.330506	0.325351	0.340509
0.0200	0.339698	0.338507	0.336682	0.344531
0.1000	2.597284	0.343425	2.093464	4.800782
				2.093464

Gambar 4: Batch Size dan Learning Rate

D. Arsitektur Model

MobileNet dan MobileNet V2

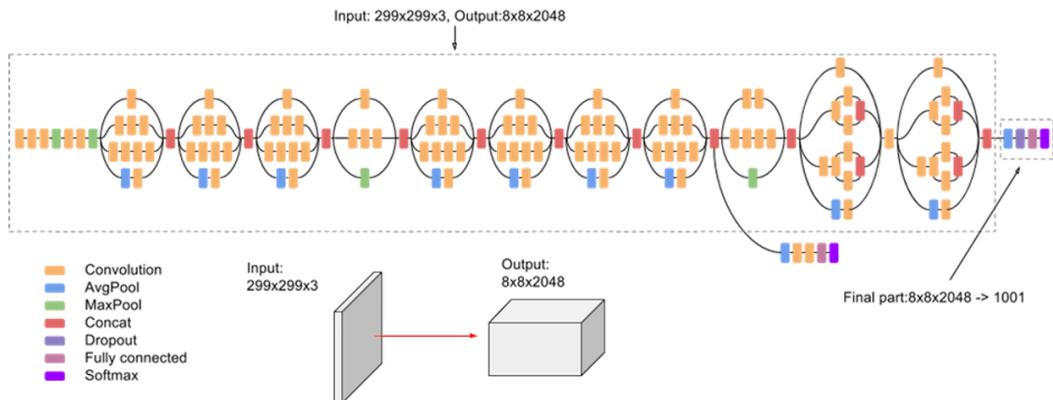
MobileNet adalah salah satu arsitektur yang sering digunakan dalam *Machine Learning*. Salah satu keunggulan dari *MobileNet* adalah kecepatan dan keringanannya. *MobileNet* menggunakan konvolusi yang dapat dipisahkan untuk mengurangi parameter selagi mempertahankan kedalaman yang sama dengan normal CNN [6].



Gambar 5: Arsitektur MobileNet

Inception

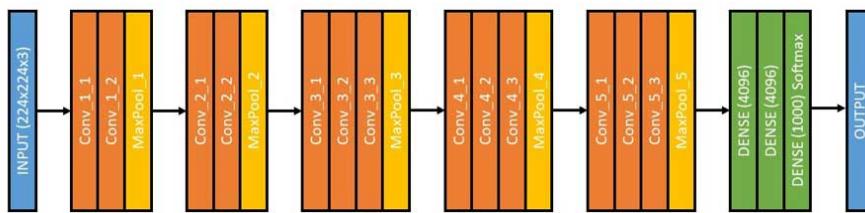
Inception adalah model image recognition yang banyak digunakan dan telah terbukti mencapai akurasi lebih dari 78.1% pada dataset ImageNet. Model ini pertama kali diperkenalkan oleh GoogLeNet. *Inception* terdiri dari blok simetris dan asimetris, yang berisikan convolution layer, average pooling, max pooling, concat, dropout, dan fully connected layer. Pada penelitian ini arsitektur yang digunakan adalah InceptionV2 dan InceptionV3 [7].



Gambar 6: Arsitektur InceptionV3

VGG-19

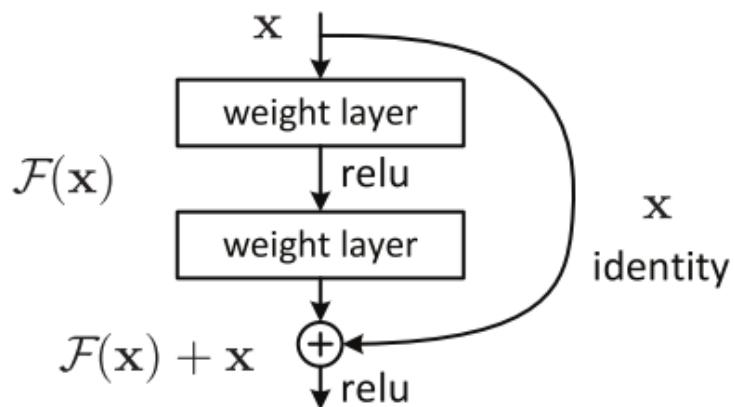
VGG-19 adalah *Convolutional Neural Network* yang sudah di-training. Angka 19 menunjukkan jumlah dari layer dengan weight yang dapat di-train. 16 *Convolutional Layer* dan 3 *Fully Connected Layer*. *Maxpool layer* digunakan untuk mengurangi ukuran dari input gambar yang nantinya akan menggunakan softmax untuk mengambil keputusan terakhir. VGG-19 di-train menggunakan Imagenet 1000-class menggunakan gambar RGB (224,224,3) [8].



Gambar 7: Arsitektur VGG-19

ResNet

Di ILSVRC 2015, Kaiming He, Xiangyu Zhang, Shaoqing Ren, dan Jian Sun memperkenalkan *Residual Neural Network* (ResNet). ResNet adalah arsitektur yang unik karena memiliki “residual blocks” [9], yang memungkinkan satu atau lebih layer untuk dilewati. Seperti pada Gambar 8.



Gambar 8: Residual Block ResNet

III. HASIL DAN PENGUJIAN

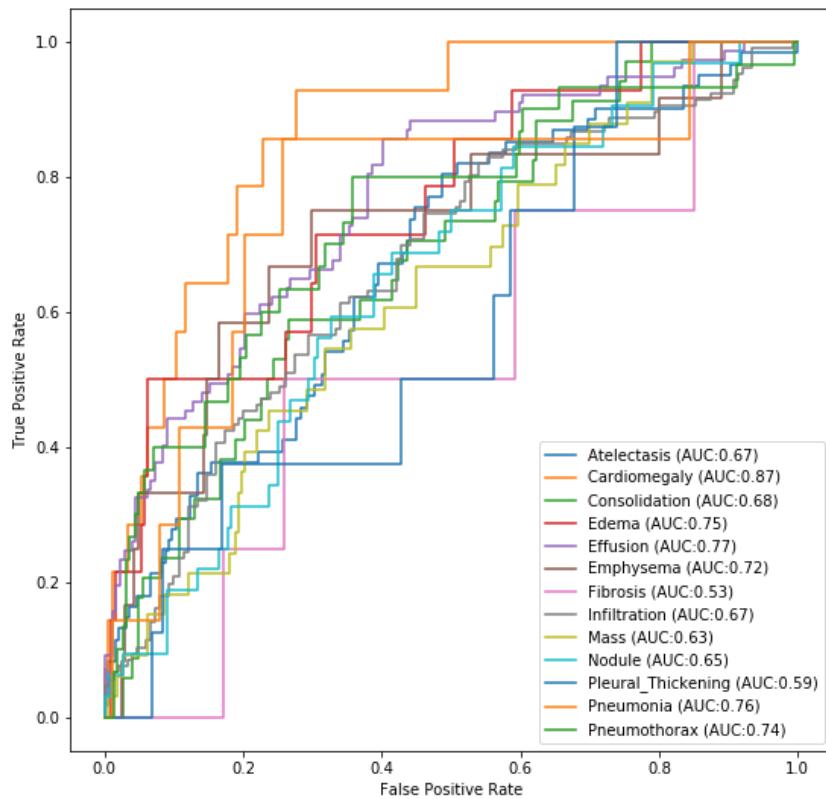
A. MobileNet V1

Pengujian tersebut dilakukan menggunakan arsitektur MobileNet dan menambahkan dense layer dengan sigmoid berfungsi sebagai activation function untuk prediksi. Spesifikasi hasil training menggunakan model arsitektur MobileNet V1 dapat dilihat pada Tabel 1.

Tabel 1: Spesifikasi Menggunakan Arsitektur MobileNet V1

Metrik	Nilai
Loss	0.2864
Binary Accuracy	0.8850
Mean Absolute Error	0.1711
Validation Loss	0.3029
Validation Binary Accuracy	0.8793
Validation Mean Absolute Error	0.1714

Menggunakan arsitektur MobileNet V1 kita melakukan training dan mendapatkan hasil penyakit *Pneumothorax* memiliki AUC bernilai 0.74 seperti yang terdapat pada Gambar 9.



Gambar 9: ROC Arsitektur MobileNet V1

Testing yang dilakukan menggunakan test set menunjukkan bahwa sistem dapat mendeteksi penyakit sesuai dengan label yang ada. Positive example untuk penyakit *Pneumothorax* adalah 10.55% sementara deteksi yang berhasil dilakukan bernilai 10.72% ini menandakan bahwa terjadi overfitting dalam pendekripsi. Nilai ini dapat dilihat pada Gambar 10.

Atelectasis: Dx: 23.05%, PDx: 19.71%
Cardiomegaly: Dx: 7.42%, PDx: 8.54%
Consolidation: Dx: 11.72%, PDx: 8.78%
Edema: Dx: 7.81%, PDx: 6.00%
Effusion: Dx: 31.25%, PDx: 22.34%
Emphysema: Dx: 3.91%, PDx: 4.67%
Fibrosis: Dx: 3.91%, PDx: 2.46%
Infiltration: Dx: 41.80%, PDx: 43.09%
Mass: Dx: 10.55%, PDx: 11.27%
Nodule: Dx: 11.72%, PDx: 12.16%
Pleural_Thickening: Dx: 4.30%, PDx: 6.12%
Pneumonia: Dx: 3.12%, PDx: 3.43%
Pneumothorax: Dx: 10.55%, PDx: 10.72%

Gambar 10: Positive Example dan Deteksi untuk Setiap Kategori Menggunakan Arsitektur MobileNet V1

B. MobileNet V2

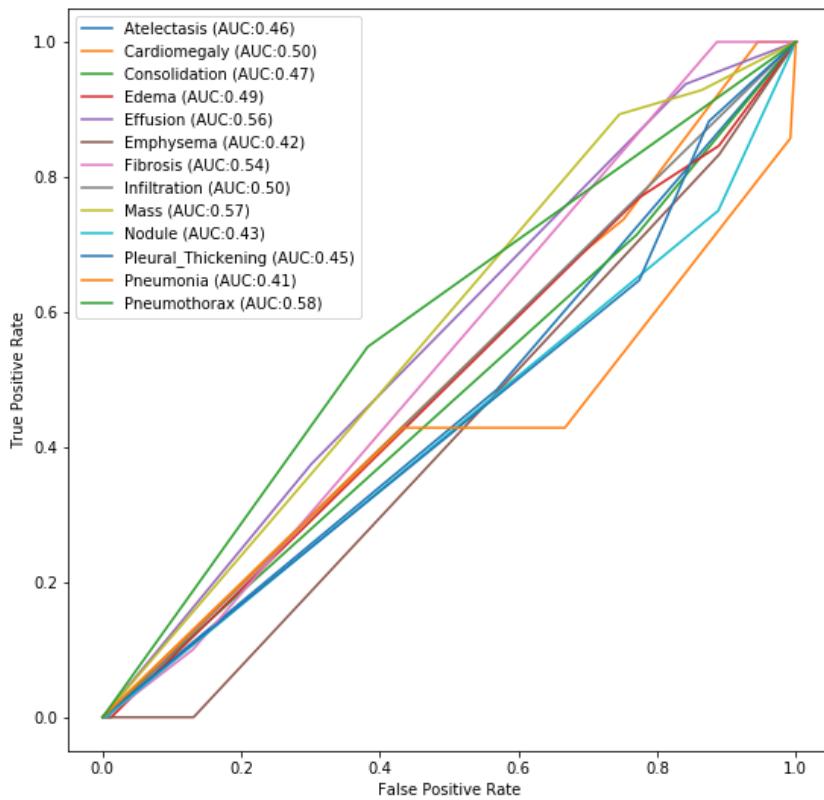
Spesifikasi hasil training menggunakan model arsitektur MobileNet V2 dapat dilihat pada Tabel 2.

Tabel 2: Spesifikasi Menggunakan Arsitektur MobileNet V2

Metrik	Nilai
Loss	0.3605
Binary Accuracy	0.8686
Mean Absolute Error	0.1729
Validation Loss	0.3614
Validation Binary Accuracy	0.8684
Validation Mean Absolute Error	0.1730

Menggunakan arsitektur MobileNet V2 kita melakukan training dan mendapatkan hasil penyakit yang memiliki nilai paling tinggi adalah *Pneumothorax* dengan AUC bernilai 0.58 seperti yang terdapat pada Gambar 11.

Testing menggunakan test set menunjukkan sistem dapat mendeteksi penyakit sesuai dengan label. Positive example untuk penyakit *Pneumothorax* adalah 10.55% sementara deteksi yang berhasil dilakukan bernilai 6.29% ini menandakan terjadinya underfitting dalam pendekstian. Nilai ini dapat dilihat pada Gambar 12.



Gambar 11: ROC Arsitektur MobileNet V2

Atelectasis: Dx: 23.05%, PDx: 13.51%
Cardiomegaly: Dx: 7.42%, PDx: 3.26%
Consolidation: Dx: 11.72%, PDx: 6.00%
Edema: Dx: 7.81%, PDx: 2.71%
Effusion: Dx: 31.25%, PDx: 16.67%
Emphysema: Dx: 3.91%, PDx: 2.90%
Fibrosis: Dx: 3.91%, PDx: 2.09%
Infiltration: Dx: 41.80%, PDx: 26.14%
Mass: Dx: 10.55%, PDx: 7.28%
Nodule: Dx: 11.72%, PDx: 7.31%
Pleural_Thickening: Dx: 4.30%, PDx: 4.15%
Pneumonia: Dx: 3.12%, PDx: 1.67%
Pneumothorax: Dx: 10.55%, PDx: 6.29%

Gambar 12: Positive Example dan Deteksi untuk Setiap Kategori Menggunakan Arsitektur MobileNet V2

C. VGG-19

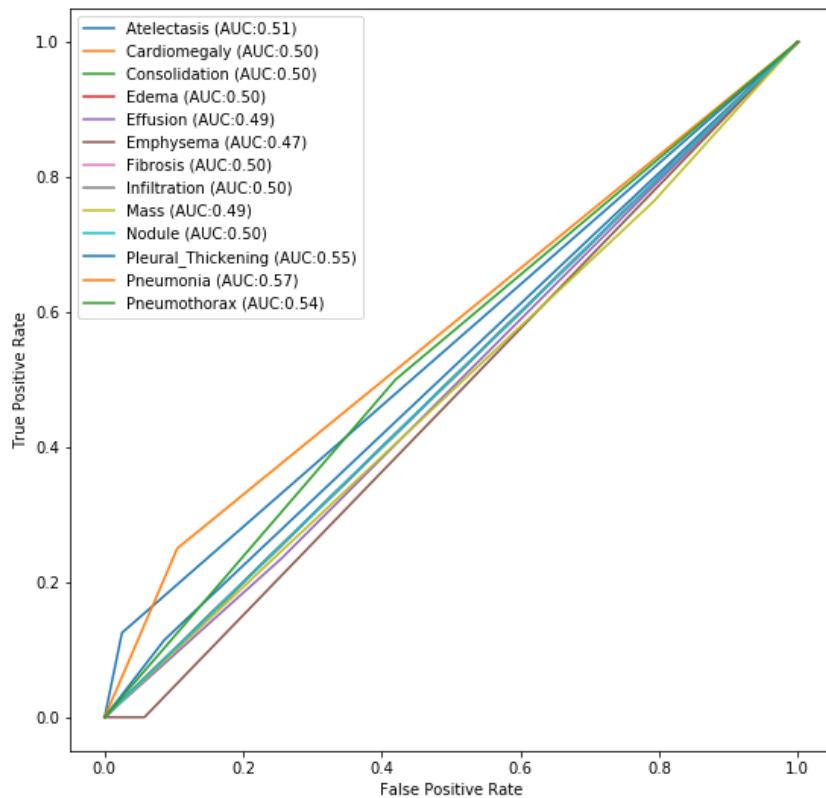
Spesifikasi hasil training menggunakan model arsitektur VGG-19 dapat dilihat pada Tabel 3.

Tabel 3: Spesifikasi Menggunakan Arsitektur VGG-19

Metrik	Nilai
Loss	0.3469
Binary Accuracy	0.8667
Mean Absolute Error	0.2000
Validation Loss	0.3420
Validation Binary Accuracy	0.8684
Validation Mean Absolute Error	0.2046

Menggunakan arsitektur VGG-19 kita melakukan training dan mendapatkan hasil penyakit *Pneumothorax* memiliki AUC bernilai 0.54 seperti yang terdapat pada Gambar 13. Sementara Positive Example menggunakan arsitektur VGG-19 dapat dilihat pada Gambar 14.

Positive example untuk penyakit *Pneumothorax* adalah 10.55% sementara deteksi yang berhasil dilakukan bernilai 54.21%. Dapat disimpulkan bahwa menggunakan model arsitektur VGG-19 mengalami overfitting yang cukup besar.



Gambar 13: ROC Arsitektur VGG-19

Atelectasis: Dx: 23.05%, PDx: 72.76%
Cardiomegaly: Dx: 7.42%, PDx: 33.05%
Consolidation: Dx: 11.72%, PDx: 44.98%
Edema: Dx: 7.81%, PDx: 28.58%
Effusion: Dx: 31.25%, PDx: 74.10%
Emphysema: Dx: 3.91%, PDx: 32.13%
Fibrosis: Dx: 3.91%, PDx: 22.67%
Infiltration: Dx: 41.80%, PDx: 80.19%
Mass: Dx: 10.55%, PDx: 53.74%
Nodule: Dx: 11.72%, PDx: 51.16%
Pleural_Thickening: Dx: 4.30%, PDx: 41.01%
Pneumonia: Dx: 3.12%, PDx: 18.27%
Pneumothorax: Dx: 10.55%, PDx: 54.21%

Gambar 14: Positive Example dan Deteksi untuk Setiap Kategori Menggunakan Arsitektur VGG-19

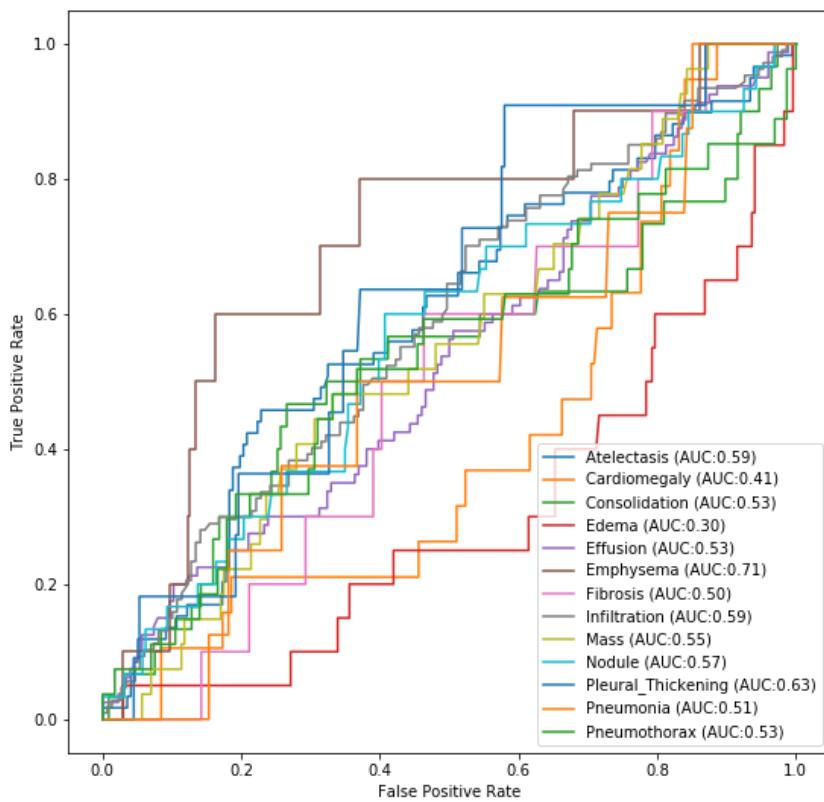
D. Inception V3

Spesifikasi hasil training menggunakan model arsitektur InceptionV3 dapat dilihat pada Tabel 4.

Tabel 4: Spesifikasi Menggunakan Arsitektur InceptionV3

Metrik	Nilai
Loss	0.3367
Binary Accuracy	0.8693
Mean Absolute Error	0.2024
Validation Loss	0.3417
Validation Binary Accuracy	0.8684
Validation Mean Absolute Error	0.2067

Menggunakan arsitektur InceptionV3 kita melakukan training dan mendapatkan hasil penyakit *Pneumothorax* memiliki AUC bernilai 0.53 seperti yang terdapat pada Gambar 15. Testing menggunakan test set menunjukkan bahwa sistem dapat mendeteksi penyakit sesuai dengan label yang ada. Positive example untuk penyakit *Pneumothorax* adalah 10.55% sementara deteksi yang berhasil dilakukan bernilai 12.39%. Dapat disimpulkan bahwa menggunakan model arsitektur Inception V3 mengalami overfitting.



Gambar 15: ROC Arsitektur Inception V3

Atelectasis: Dx: 23.05%, PDx: 23.68%
Cardiomegaly: Dx: 7.42%, PDx: 6.37%
Consolidation: Dx: 11.72%, PDx: 10.95%
Edema: Dx: 7.81%, PDx: 6.02%
Effusion: Dx: 31.25%, PDx: 29.44%
Emphysema: Dx: 3.91%, PDx: 5.72%
Fibrosis: Dx: 3.91%, PDx: 3.70%
Infiltration: Dx: 41.80%, PDx: 41.80%
Mass: Dx: 10.55%, PDx: 12.44%
Nodule: Dx: 11.72%, PDx: 13.22%
Pleural_Thickness: Dx: 4.30%, PDx: 7.45%
Pneumonia: Dx: 3.12%, PDx: 3.32%
Pneumothorax: Dx: 10.55%, PDx: 12.39%

Gambar 16: Positive Example dan Deteksi untuk Setiap Kategori Menggunakan Arsitektur Inception V3

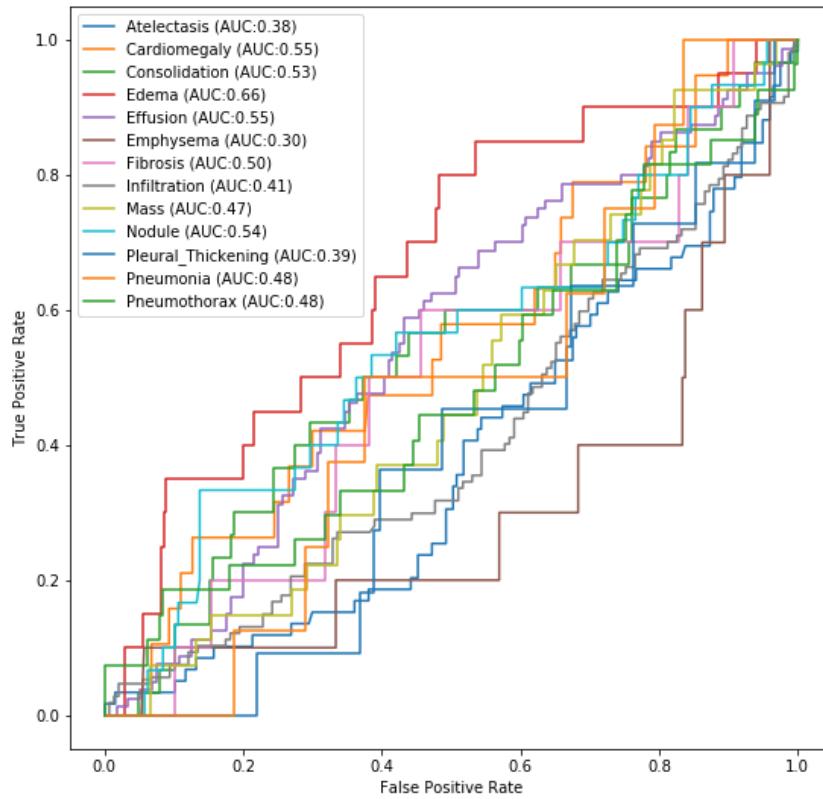
E. Inception ResNet V2

Spesifikasi hasil training menggunakan model arsitektur Inception ResNet V2 dapat dilihat pada Tabel 5.

Tabel 5: Spesifikasi Menggunakan Arsitektur Inception ResNet V2

Metrik	Nilai
Loss	0.3518
Binary Accuracy	0.8665
Mean Absolute Error	0.1996
Validation Loss	0.3446
Validation Binary Accuracy	0.8684
Validation Mean Absolute Error	0.2125

Menggunakan arsitektur Inception ResNet V2 kita melakukan training dan mendapatkan hasil penyakit *Pneumothorax* memiliki AUC bernilai 0.48 seperti yang terdapat pada Gambar 17.



Gambar 17: ROC Arsitektur Inception Resnet V2

Positive example untuk penyakit *Pneumothorax* adalah 10.55% sementara deteksi yang berhasil dilakukan bernilai 12.78%. Dapat disimpulkan bahwa menggunakan model arsitektur Inception ResNet V2 mengalami overfitting.

```
Atelectasis: Dx: 23.05%, PDx: 25.20%
Cardiomegaly: Dx: 7.42%, PDx: 7.50%
Consolidation: Dx: 11.72%, PDx: 10.54%
Edema: Dx: 7.81%, PDx: 4.42%
Effusion: Dx: 31.25%, PDx: 30.08%
Emphysema: Dx: 3.91%, PDx: 6.95%
Fibrosis: Dx: 3.91%, PDx: 5.19%
Infiltration: Dx: 41.80%, PDx: 38.13%
Mass: Dx: 10.55%, PDx: 13.70%
Nodule: Dx: 11.72%, PDx: 14.32%
Pleural_Thickening: Dx: 4.30%, PDx: 9.68%
Pneumonia: Dx: 3.12%, PDx: 4.17%
Pneumothorax: Dx: 10.55%, PDx: 12.78%
```

Gambar 18: Positive Example dan Deteksi untuk Setiap Kategori Menggunakan Arsitektur Inception Resnet V2

IV. KESIMPULAN

Berdasarkan hasil pengujian awal, dapat disimpulkan bahwa sistem dapat bekerja dengan baik. Untuk lebih detail, dapat ditarik kesimpulan sebagai berikut:

1. Dalam penelitian ini, telah diimplementasikan serangkaian prosedur untuk memprediksi kondisi paru-paru melalui citra x-ray dengan menggunakan *Convolutional Neural Network*.
2. Berdasarkan hasil pengujian menggunakan *test set*, model yang memiliki performansi deteksi rendah terhadap kondisi *Pneumothorax* yaitu VGG-19 dengan persentase prediksi paling rendah yaitu 19.5%.
3. Berdasarkan hasil pengujian menggunakan *test set*, model yang memiliki performansi deteksi tinggi terhadap kondisi *Pneumothorax* yaitu MobileNet V1 dengan persentase prediksi paling tinggi yaitu 98.4%.
4. Nilai validasi akurasi yang didapat jika dilakukan proses training menggunakan model arsitektur sudah cukup tinggi, namun deteksi sistem masih terhitung rendah.

Daftar Pustaka

- [1] M. Noppen and T. De Keukeleire, “Pneumothorax,” *Respiration*, vol. 76, no. 2, pp. 121–127, 2008.
- [2] U.S. National Library of Medicine, “Spontaneous pneumothorax,” 2008.
- [3] X. Wang, Y. Peng, L. Lu, Z. Lu, M. Bagheri, and R. M. Summers, “ChestX-ray8: Hospital-scale chest x-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, July 2017.
- [4] A. Goßen, H. Deshpande, T. Harder, E. Schwab, I. Baltruschat, T. Mabotuwana, N. Cross, and A. Saalbach, “Deep learning for pneumothorax detection and localization in chest radiographs,” *arXiv preprint*, no. arXiv:1907.07324, 2019.
- [5] M. T. Islam, M. A. Aowal, A. T. Minhaz, and K. Ashraf, “Abnormality detection and localization in chest x-rays using deep convolutional neural networks,” *arXiv preprint*, no. arXiv:1705.09850, 2017.

- [6] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto, and H. Adam, “Mobilenets: Efficient convolutional neural networks for mobile vision applications,” *arXiv preprint*, no. abs/1704.04861, 2017.
- [7] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, “Rethinking the inception architecture for computer vision,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016, pp. 2818–2826.
- [8] L. Wen, X. Li, and L. Gao, “A new transfer learning based on vgg-19 network for fault diagnosis,” in *2019 IEEE 23rd International Conference on Computer Supported Cooperative Work in Design (CSCWD)*, 2019, pp. 205–209.
- [9] S. Targ, D. Almeida, and K. Lyman, “Resnet in resnet: Generalizing residual architectures,” *arXiv preprint*, no. abs/1603.08029, 2016.