

# DETECTION OF LUNG CANCER CELL BASED ON CYTOLOGICAL EXAMINATION USING CONVOLUTIONAL NEURAL NETWORK

Rulisiana Widodo<sup>1</sup>, Tessy Badriyah<sup>2</sup>, Iwan Syarif<sup>3</sup>

<sup>1,2,3</sup>Politeknik Elektronika Negeri Surabaya  
Kampus PENS Jl. Raya ITS Sukolilo, Surabaya, 60111  
Email: rulisiyanaw@gmail.com

## Abstract

*Lung cancer is one of the most dangerous cases with the largest number of new cases in the world. The number of Lung Cancer in Indonesia is increasing rapidly every day until it is ranks 8th position in Southeast Asia, experiencing an increase in the last five years by 10.85 percent. This study aims to build a tool to detect lung cancer using the Deep Learning classification method with the Convolutional Neural Network (CNN) Algorithm. The tools that are made can be used for consideration in detecting from the results of cytological examinations=can be classified into normal (negative) and abnormal (positive) types of cancer. The experiment was carried out by performing hyperparameter optimization. The results show that the hyperparameter optimization has superior results compared to others, using the hyperparameter Gradient Boosted Regression Tree method. Experiments without hyperparameters give an accuracy value of 97%, while with the Gaussian Process it gives 98% accuracy and with a hyperparameter gradient boosted regression tree gives 99% accuracy, which is the best accuracy.*

**Keywords :** Lung Cancer, Cytological Examinations, Deep Learning, Convolutional Neural Network (CNN)

## Abstrak

*Kanker paru merupakan salah satu kasus paling berbahaya dengan jumlah kasus baru terbanyak di dunia. Jumlah penderita Kanker Paru di Indonesia semakin hari semakin meningkat pesat hingga menduduki urutan ke-8 di Asia Tenggara, mengalami peningkatan dalam lima tahun terakhir sebanyak 10.85 persen. Penelitian ini bertujuan untuk membangun alat pendekripsi kanker paru menggunakan metode klasifikasi Deep Learning dengan Algoritma Convolutional Neural Network (CNN). Alat yang dibuat dapat digunakan sebagai pertimbangan dalam mendekripsi Kanker Paru dari hasil pemeriksaan sitologi, diklasifikasikan menjadi jenis normal (negatif) dan abnormal (positif) kanker. Percobaan dilakukan dengan melakukan optimasi hyperparameter. Hasil penelitian menunjukkan bahwa optimasi hyperparameter memiliki hasil yang lebih unggul yaitu dengan menggunakan metode hyperparameter Gradient Boosted Regression Tree. Percobaan tanpa hyperparameter memberikan nilai akurasi 97%, sedangkan dengan Gaussian Process memberikan akurasi 98% dan dengan hyperparameter Gradient Boosted Regression Tree memberikan akurasi terbaik yaitu 99%.*

**Kata Kunci :** Kanker Paru, Pemeriksaan Sitologi, Deep Learning, Convolutional Neural Network (CNN)

## I. PENDAHULUAN

Kanker Paru merupakan salah satu kasus paling berbahaya yang mayoritas menyerang kaum laki-laki [1]. Saat ini, merupakan Kanker dengan jumlah kasus baru terbanyak di dunia. Berdasarkan perkiraan statistik menurut *American Cancer Society* menunjukkan bahwa terdapat kasus baru sebanyak 226.160 jiwa yang telah didiagnosis, dan diperkirakan akan ada kasus kematian sebanyak 160.340 jiwa dikarenakan Kanker Paru[2]. Jumlah penderita Kanker Paru di Indonesia semakin hari semakin meningkat pesat hingga menduduki urutan ke-8 di Asia Tenggara, mengalami peningkatan dalam lima tahun terakhir sebanyak 10.85%[3][4].

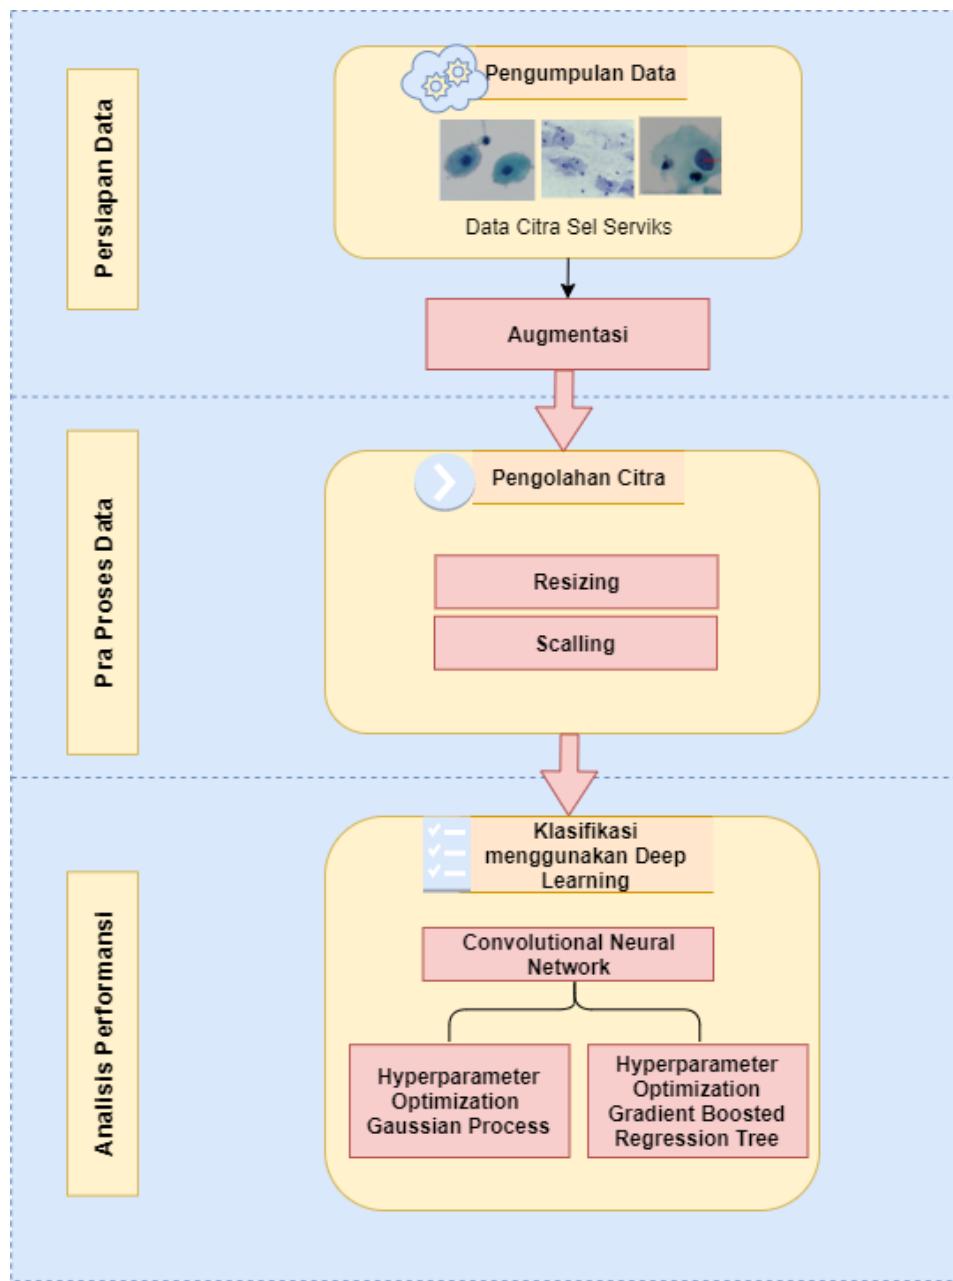
Penyebab utama dari Kanker Paru yaitu kebiasaan Merokok, namun tidak menutup kemungkinan mereka sebagai perokok pasif pun dapat beresiko terkena Kanker Paru[5]. Terdapat beberapa teknik pemeriksaan pada Kanker Paru, diantaranya menggunakan Pemeriksaan Sitologi untuk mendeteksi adanya sel kanker di daerah yang mengelilingi paru-paru[6]. Hasil pemeriksaan sitologi yang dilakukan di Laboratorium Patologi Anatomi memberikan gambaran bagaimana kondisi sel, lokasi dan luasnya infeksi, yang kemudian dianalisa dan divalidasi oleh dokter Patologi Anatomi, dimana seorang dokter berperan besar dalam memanajemen dan membaca hasil dari pemeriksaan sitologi melalui mikroskop, sehingga pengetahuan tentang anatomi patofisiologi dasar kanker, manifestasi klinis dan gambaran mikroskopik sangat penting dimiliki oleh dokter[7].

Perkembangan teknologi informasi saat ini begitu transformatif dan inovatif terutama di bidang *image processing* yang dapat diolah dengan memanfaatkan algoritma *deep learning* berupa *classification*. *Deep learning* merupakan sebuah algoritma jaringan syaraf tiruan yang memiliki fitur unik sehingga mampu mengekstraksi secara otomatis. Semakin hari penggunaan *Deep Learning* mengalami peningkatan secara drastis, terutama di bidang *pattern recognition in the fields of speech and vision*. *Convolutional Neural Network (CNN)* merupakan salah satu bagian dari *Deep Learning* yang telah membawa terobosan di bidang *pattern recognition of images*. *CNN* menunjukkan kinerja tinggi dalam pengklasifikasian gambar secara alami sehingga dapat memberikan pengaruh besar terhadap berbagai aspek dalam kehidupan terutama di bidang kesehatan[8].

Penelitian ini bertujuan untuk membangun alat deteksi diagnosa Kanker Paru menggunakan metode klasifikasi *Deep Learning* dengan Algoritma *Convolutional Neural Network (CNN)*. Alat yang dibuat dapat digunakan sebagai pertimbangan dalam mendeteksi Kanker Paru dari hasil pemeriksaan sitologi, diklasifikasikan menjadi jenis normal (negatif) dan abnormal (positif) kanker. Data supervised memudahkan penggunaan metode *deep learning* tanpa harus ekstraksi fitur lagi, sehingga lebih efisien dan efektif dalam prosesnya[8]. Namun, diharapkan tetap mampu menghasilkan alat deteksi yang dapat memberikan hasil secara akurat. Sehingga dapat digunakan sebagai alat pendukung dan penyeragaman keputusan dokter dalam menentukan diagnosa, dikarenakan beragamnya *skill* antar dokter, serta mengantisipasi adanya kesalahan dalam pembacaan diagnosa kanker paru, sehingga sistem dapat memberikan pengaruh besar sebagai pedoman penentuan diagnosa.

## 2. METODOLOGI PENELITIAN

Berikut merupakan perancangan sistem yang akan dibangun dapat dilihat pada gambar 1. Sistem terdiri dari 3 bagian utama yaitu proses pengumpulan data (*Preparation Data*), *Pre-processing Data* dan klasifikasi *image* menggunakan *Deep Learning* (*Performance Analysis*).



Gambar 1. Desain Sistem

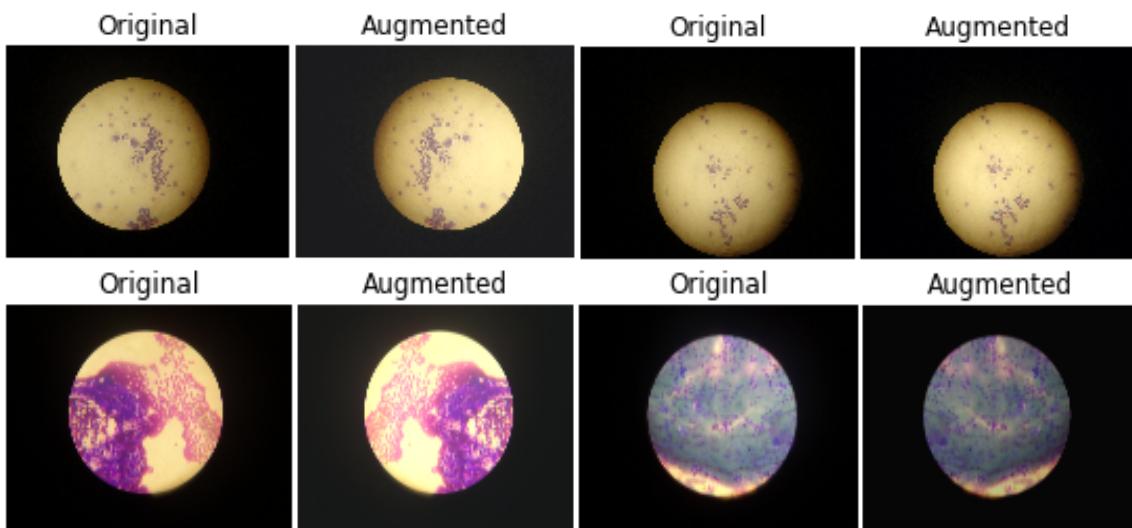
Penelitian ini digunakan untuk menentukan diagnosa pada penyakit Kanker Paru. Data awal yang digunakan yaitu dengan memanfaatkan cairan pleura yang

didapatkan dari hasil biopsi jarum halus (*Fine Needle Aspiration Biopsy*, FNAB) pada paru-paru[5][9]. Cairan pleura merupakan cairan yang berada antara lapisan pleura, selaput yang melapisi rongga dan yang mengelilingi paru-paru[10]. Kemudian, cairan tersebut diletakkan pada Slide Thin Prep untuk diamati melalui mikroskop.

Data yang diperoleh berasal dari RSUD dr. Soetomo Surabaya, dikarenakan jumlah dari data tidak terlalu banyak, maka dataset perlu dilakukan proses augmentasi untuk menghasilkan data baru tanpa menghilangkan kualitas pada gambar. Setelah itu dilakukan tahap pra proses data yang terdiri dari *Resizing* dan *Scaling*, kemudian proses klasifikasi menggunakan *Deep Learning* dengan metode *optimization hyperparameter* yang bertujuan untuk meningkatkan akurasi dari penentuan diagnosa Kanker Paru.

## 2.1. Tahap Persiapan Data

Proses persiapan data meliputi pengumpulan dan augmentasi dengan menggunakan data yang sama. Data terdiri dari dua kelas yaitu Kanker dan Normal. Proses augmentasi bertujuan sebagai strategi untuk menambah jumlah data dengan cara menambahkan salinan dan sedikit memanipulasi data tanpa kehilangan kualitas gambarnya[11]. Pada penelitian ini dilakukan augmentasi berupa flip, kecerahan dan kontras. Hasil dari proses Augmentasi dapat dilihat pada Gambar 2.



Gambar 2. Hasil dari proses Augmentasi (a) Normal (b) Kanker

Pada tahap ini diambil 2 sampel dari masing-masing kelas (Normal dan Kanker), kemudian data hasil dari augmentasi dikumpulkan ke dalam dataset baru. Hasil dari penambahan data ini akan diproses pada tahap selanjutnya. Pengukuran hasil kinerja penelitian dilakukan dengan menggunakan akurasi, presisi, *recall* dan *F1-score*.

## 2.2 Tahap Pra Proses Data

Tahap selanjutnya setelah persiapan data yaitu pra proses data. Dimana pada tahap ini meliputi proses *Resizing* dan *Scalling*.

### 2.2.1 *Resizing*

Merupakan proses yang ditujukan untuk membuat ukuran *image* menjadi ukuran yang dibutuhkan oleh sistem[12]. Pada umumnya untuk ukuran dari *image* semakin besar, maka akurasi yang didapat akan semakin besar pula, namun menjadikan waktu trainingnya semakin lama. Dataset *image* yang didapat pada penelitian ini memiliki ukuran 4896 x 3672. Untuk mengurangi waktu training yang lama, maka dataset perlu di *resize* menjadi ukuran lebih kecil. Di sini *image* dilakukan pengubahan ukuran menjadi 456 x 456 untuk *height* maupun *weight*.

### 2.2.2 *Scalling*

*Scaling* merupakan proses untuk pembesaran atau pengurangan jumlah piksel dari gambar [12]. Pada penelitian ini dilakukan pengurangan piksel dari dataset. Nilai piksel gambar dari *range* [0, 255] diubah menjadi *range* [0, 1]. Selain itu, fungsi dari *scalling* yaitu mengurangi waktu pengolahan, karena semakin banyak piksel yang digunakan maka semakin lama waktu yang dilakukan untuk pemrosesan. Hal ini dikarenakan *Neural Network* bekerja ideal pada nilai input yang kecil [11].

## 2.3 Tahap Analisis Performansi

Merupakan tahap dimana penentuan citra berfokus pada tujuan yang akan dicapai. Penelitian ini menggunakan teknik klasifikasi dengan metode *Deep Learning* algoritma *Convolutional Neural Network* (CNN). Proses klasifikasi untuk memprediksi kategori dari nilai atau dataset yang telah dilakukan serangkaian tahap pra proses, langkah selanjutnya dilakukan pengklasifikasian dataset kemudian uji coba/*testing* untuk menentukan kelas yang sesuai dengan ciri dan karakteristik data. Dimana data awal telah diberikan label dengan 2 kelas yaitu label Kanker dan Normal. Penggunaan metode *Deep Learning* akan berpengaruh signifikan terhadap data yang akan diuji terhadap sistem.

Performansi dari CNN diharapkan mampu menunjukkan kinerja yang bagus dengan menggunakan salah satu arsitektur dari *CNN* yaitu *Efficientnet*. Arsitektur CNN ini bekerja dengan cara melakukan penskalaan terhadap kedalaman, lebar dan resolusi secara bersamaan sekaligus, yang disebut *compound scaling*. Dengan metode ini, tidak hanya memberikan akurasi yang lebih baik tetapi juga meningkatkan efisiensi model dengan mengurangi parameter dan manifold *FLOPS* (*Floating Point Operations Per Second*). Adapun dari segi akurasi, model *EfficientNet* memberikan akurasi yang lebih tinggi dan efisiensi yang lebih baik dibanding arsitektur *CNN* lainnya [13].

## 2.4 *Deep Learning* menggunakan *Hyperparameter*

Penentuan *hyperparameter* yang akan digunakan sangatlah penting ditentukan terlebih dahulu dengan nilai-nilainya sebelum dilakukannya proses optimisasi *hyperparameter*. Terdapat banyak jenis *hyperparameter* yang dimiliki

oleh *Deep Learning*. Penelitian ini menggunakan metode *Gaussian Process* dan *Gradient Boosted Regression Tree* untuk mengoptimalkan *hyperparameter*. Berikut penjelasan kinerja klasifikasi yang digunakan dalam penelitian ini dengan mencari nilai pengukuran kinerja.

- a.  $Accuracy = \frac{TP+TN}{(TP+FP+FN+TN)} \times 100\%$
- b.  $Precision = \frac{TP}{(TP+FP)} \times 100\%$
- c.  $Recall = \frac{TP}{(TP+FN)} \times 100\%$
- d.  $F1 Score = 2 \times (Recall \times Precision) / (Recall + Precision)$

### 3. HASIL DAN PEMBAHASAN

Pada penelitian ini telah dilakukan beberapa proses yang dimulai dari pengumpulan data citra sel kanker paru, kemudian dilakukan pengolahan citra dengan *resizing* dan *scalling image*, serta analisis performansi dengan menggunakan metode *Deep Learning* algoritma CNN. Proses klasifikasi dengan *Deep Learning* menghasilkan karakteristik data dengan 2 label yaitu Normal dan Kanker. Berikutnya akan dibahas mengenai penggunaan metode *Deep Learning* dan pengoptimalkan *hyperparameter* menggunakan metode *Gaussian Process* dan *Gradient Boosted Regression Tree* untuk meningkatkan kinerja.

#### 3.1 Deep Learning tanpa *hyperparameter*

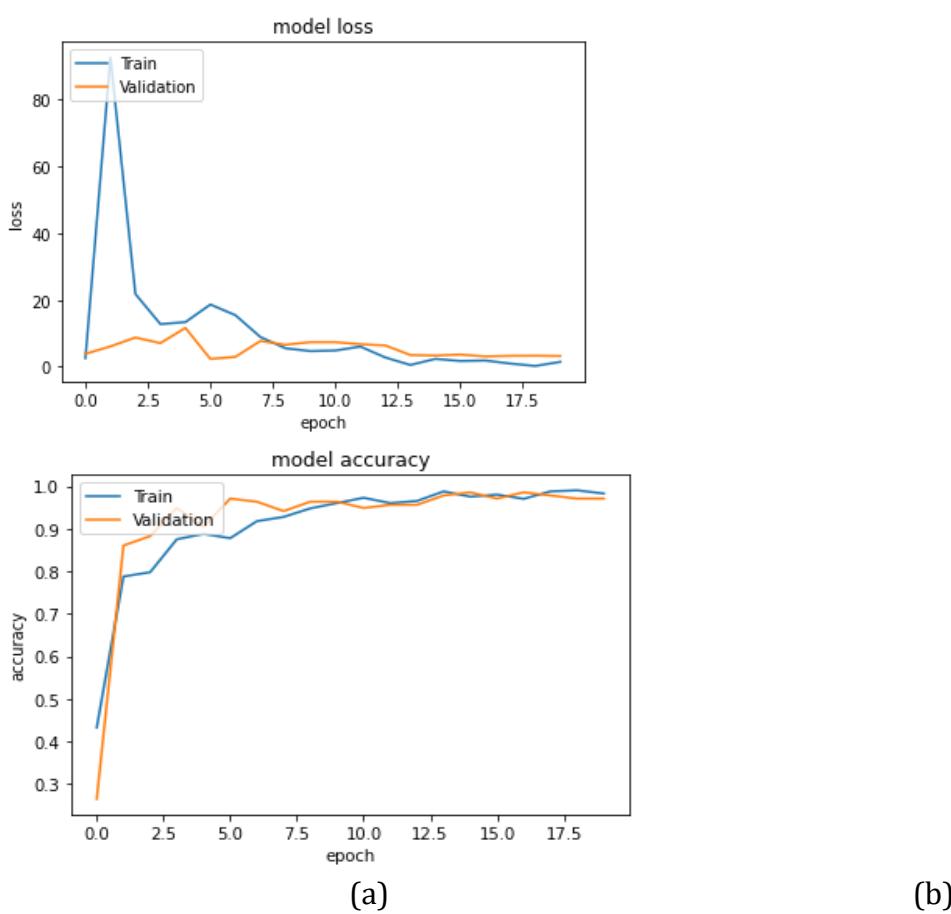
Pada tahap ini dilakukan pengujian data tes tanpa menggunakan pengoptimalkan *hyperparameter*. Validasi data *train* dan data *test* menggunakan *Train Test Split*. Penggunaan klasifikasi *CNN* dengan mengoptimalkan algoritma *Efficientnet* dengan parameter *batch size* 16, *learning rate* 0.005 dan *Epoch* 20. Struktur *Efficientnet* terdiri dari 1 *flatten layer* dan 1 *output layer* [12]. Hasil kinerja dari *CNN* ditunjukkan pada tabel berikut :

Tabel 2. Klasifikasi *Deep Learning* tanpa *hyperparameter*

Epoch	Performance Measurement	
	Loss	Accuracy
1	2.54	43%
2	92.74	78%
3	21.80	79%
4	12.78	87%
5	13.37	88%
6	18.65	87%
7	15.46	91%
8	8.90	92%
9	5.54	94%
10	4.68	96%
11	4.86	97%

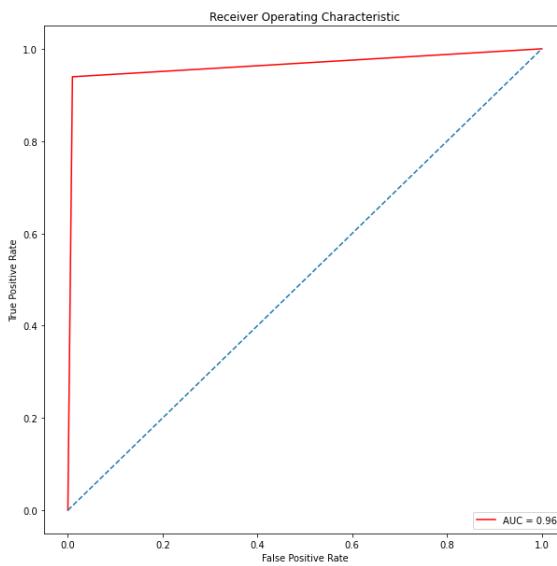
Epoch	Performance Measurement	
	Loss	Accuracy
12	6.04	96%
13	2.77	96%
14	0.53	98%
15	2.34	97%
16	1.72	98%
17	1.86	97%
18	0.95	98%
19	0.24	97%
20	1.45	97%

Hasil dari proses *training* menghasilkan *loss* per *epoch* dan akurasinya untuk data *train* dan *validation* seperti pada tabel 1. Nilai *Loss* masih menunjukkan angka 0.1 hingga 0.2 (Gbr. 4 (a)) sedangkan nilai akurasi sebagian besar pada angka 80% hingga 90% (Gbr. 4 (b)), oleh karenanya tidak terdapat indikasi *overfitting*.



Gambar 4. Hasil plot dari model *Loss* (a) dan *Accuracy* (b) Klasifikasi Deep Learning tanpa *hyperparameter*

Berikut merupakan kurva ROC yang didapat dari hasil klasifikasi pada Tabel 2.



Gambar 5. Kurva ROC klasifikasi *Deep Learning* tanpa *hyperparameter*

Hasil kinerja yang ditunjukkan oleh kurva ROC (Gbr. 5) mendekati angka 1.0. hal ini berarti teknik *Deep Learning* tanpa *hyperparameter* dapat dikatakan bagus, begitu pula dengan nilai AUC menunjukkan 0.96.

### 3.2 Deep Learning dengan *hyperparameter optimization*

Pada percobaan sebelumnya telah dilakukan klasifikasi tanpa pengoptimalan *hyperparameter* sehingga hasil yang didapat kurang memuaskan (Tabel 1). Oleh karenanya perlu dilakukan perbaikan agar hasil akurasi yang didapatkan lebih tinggi. Penelitian ini menggunakan pengoptimalan *hyperparameter* dengan metode *Gaussian Process* dan *Gradient Boosted Regression Tree*. Berikut hasil percobaan dari masing-masing *hyperparameter*.

#### 3.2.1 Hyperparameter Optimization menggunakan *Gaussian Process*

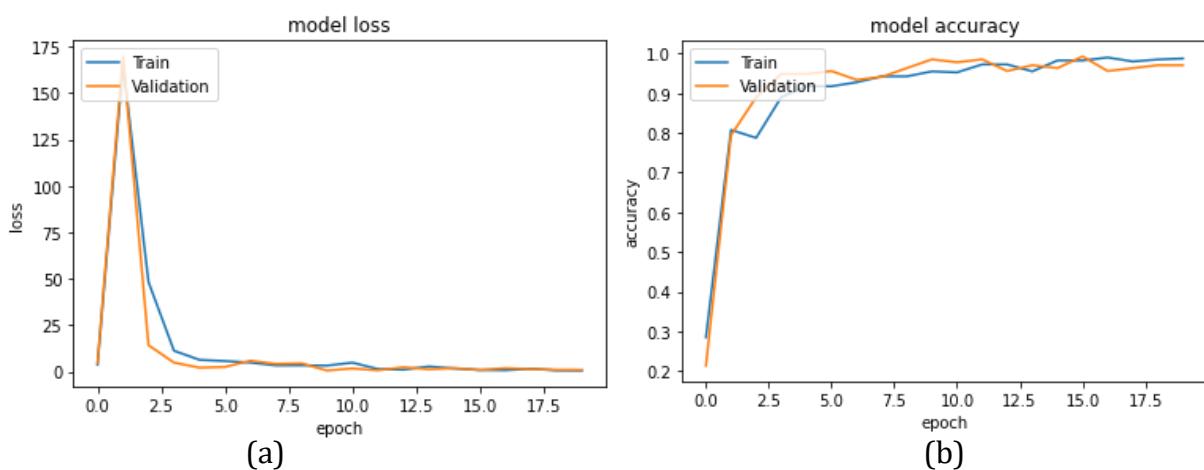
Hasil pengoptimalan *hyperparameter* dengan menggunakan *Gaussian Process* menghasilkan nilai akurasi yaitu pada angka 0.97 atau 97%. Berikut hasil dari klasifikasi dengan *hyperparameter Gaussian Process* dengan parameter *batch size* 16, *learning rate* 0.005 dan *Epoch* 20.

Tabel 2. Klasifikasi *Deep Learning* menggunakan *Gaussian Process*

Epoch	Performance Measurement	
	Loss	Accuracy
1	3.83	28%
2	165.37	80%
3	48.30	78%
4	11.29	89%
5	6.39	91%
6	5.37	91%
7	4.93	92%
8	3.38	94%

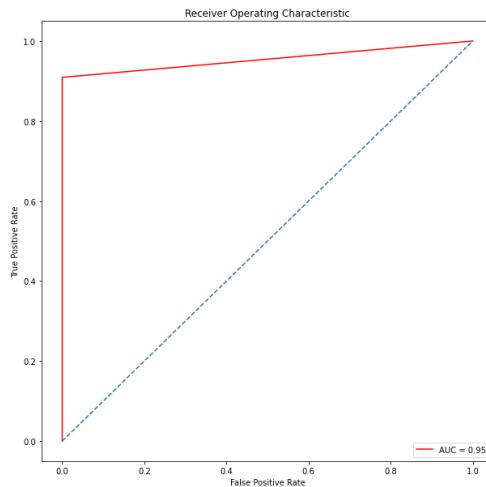
Epoch	Performance Measurement	
	Loss	Accuracy
9	3.41	94%
10	3.29	95%
11	4.88	95%
12	1.45	97%
13	1.09	97%
14	2.81	95%
15	1.74	98%
16	0.93	98%
17	0.80	99%
18	1.62	98%
19	0.71	98%
20	0.64	98%

Hasil percobaan klasifikasi *Deep Learning* dengan menggunakan *hyperparameter Gaussian Process* menunjukkan hasil yang lebih baik dengan nilai *Loss* pada angka 0.64 (Gambar 6 (a)), sedangkan nilai akurasi mengalami peningkatan yaitu 0.97 atau 97% (Gambar 6 (b)).



Gambar 6. Hasil plot dari model *Loss* (a) dan *Accuracy* (b) Klasifikasi *Deep Learning* menggunakan *hyperparameter Gaussian Process*

Berikut merupakan kurva ROC yang didapat dari hasil klasifikasi pada Tabel 2. Hasil *performance measurement* memiliki kinerja yang bagus dengan mendekati angka 1.0



Gambar 7. Kurva ROC Klasifikasi *Deep Learning* menggunakan *hyperparameter Gaussian Process*

### 3.2.2 Hyperparameter Optimization menggunakan Gradient Boosted Regression Tree

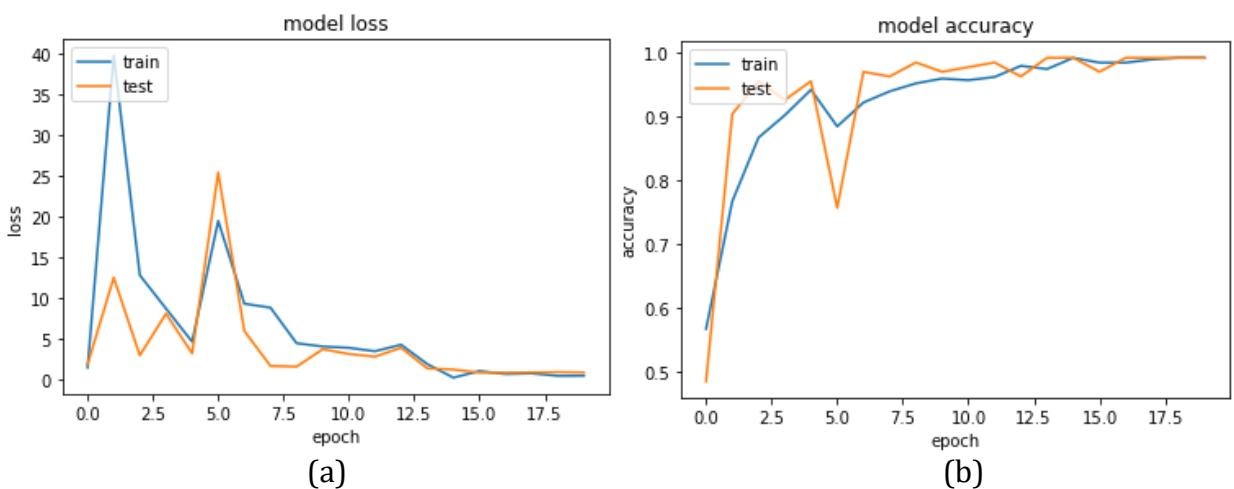
Hasil pengoptimalan *hyperparameter* dengan menggunakan *Gradient Boosted Regression Tree* menghasilkan nilai akurasi yang lebih baik diantara sebelumnya yaitu pada angka 0.99 atau 99%. Berikut hasil dari klasifikasi dengan *hyperparameter Gradient Boosted Regression Tree* dengan parameter *batch size* 16, *learning rate* 0.005 dan *Epoch* 20.

Tabel 3. Klasifikasi *Deep Learning* menggunakan *Gradient Boosted Regression Tree*

Epoch	Performance Measurement	
	Loss	Accuracy
1	1.44	56%
2	39.71	76%
3	12.77	86%
4	8.68	90%
5	4.62	94%
6	19.42	88%
7	9.27	92%
8	8.79	94%
9	4.43	95%
10	4.03	96%
11	3.86	95%
12	3.45	96%
13	4.24	98%
14	1.87	97%
15	0.20	99%
16	1.01	98%
17	0.65	98%
18	0.73	99%

Epoch	Performance Measurement	
	Loss	Accuracy
19	0.42	99%
20	0.44	99%

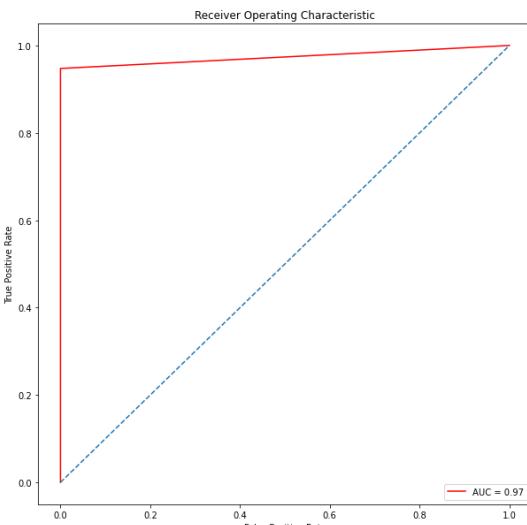
Hasil percobaan klasifikasi *Deep Learning* dengan menggunakan *hyperparameter Gradient Boosted Regression Tree* menunjukkan hasil yang lebih baik dengan nilai *Loss* pada angka 0.44 (Gambar 8 (a)), sedangkan nilai akurasi masih pada angka yang sama yaitu 0.99 (Gambar 8 (b)).



Gambar 8. Hasil plot dari model *Loss* (a) dan *Accuracy* (b) Klasifikasi *Deep Learning* menggunakan *hyperparameter Gradient Boosted Regression Tree*

Hasil percobaan dengan pengoptimalan *hyperparameter* *Gradient Boosted Regression Tree* memberikan hasil yang memuaskan dengan nilai skor yang sangat tinggi yaitu 0,99 atau 99% (Tabel 3). Hasil akhir *hyperparameter* berikut sangat berbeda dengan *hyperparameter* yang sebelumnya yaitu *Gaussian Process*. Hasil plot *loss per epoch* (Gbr. 8 (a)), *accuracy per epoch* (Gbr. 8 (b)), dan *scoring* menghasilkan angka yang sangat bagus. Hal ini berarti hasil tersebut berbanding lurus dengan hasil kurva ROC

pada Gambar 9, yang menunjukkan hasil klasifikasi yang sangat baik dengan nilai AUC berada pada angka 0.97.



Gambar 9. Kurva ROC Klasifikasi *Deep Learning* menggunakan *hyperparameter Gradient Boosted Regression Tree*

Berikut merupakan tabel perbandingan penggunaan Klasifikasi *Deep Learning* dengan dan tanpa pengoptimalan *hyperparameter*.

Tabel 4. Perbandingan penggunaan *hyperparameter*

Perbandingan Matriks	Without Hyperparameter	Using Hyperparameter	
		Gaussian Process	Gradient Boosted Regression Tree
Akurasi	97%	98%	99%
Presisi	91%	94%	96%
Recall	97%	97%	98%
F1 - Score	94%	95%	97%
Waktu Optimisasi	00.02.60	00.02.63	00.04.40

Penggunaan dataset Kanker memberikan hasil yang efektif dan efisien ketika dilakukan klasifikasi *Deep Learning* dengan pengoptimalan *Hyperparameter Gradient Boosted Regression Tree*, dimana menghasilkan akurasi sebesar 0.99 atau 99%. Meskipun begitu metode pengklasifikasian *Deep Learning* lebih baik daripada metode yang lainnya.

#### 4. SIMPULAN

Kanker Paru merupakan kasus paling berbahaya yang mayoritas menyerang kaum laki-laki dengan jumlah kasus baru terbanyak di dunia. Penelitian ini dilakukan untuk menghasilkan alat deteksi Kanker Paru dengan menggunakan metode *Deep Learning* algoritma *CNN*. Terdapat 3 tahapan yaitu proses pengumpulan data, pengolahan citra dan proses klasifikasi. Hasil penelitian menggunakan algoritma *CNN* didapatkan nilai akurasi yang cukup tinggi, namun tetap diupayakan dengan membandingkan penggunaan *hyperparameter* untuk meningkatkan akurasi. Secara keseluruhan dapat disimpulkan bahwa penggunaan *Deep Learning* dengan pemilihan metode *CNN* algoritma *Efficientnet* bekerja dengan

baik dengan atau tanpa pengoptimalan *hyperparameter*, sehingga mampu menghasilkan nilai akurasi sebesar 99%. Pada penelitian selanjutnya, peneliti akan memaksimalkan dalam pra proses data sehingga mampu mengurangi beban komputasi dan waktu pelatihan. Peneliti juga akan berusaha mempertimbangkan penggunaan *machine learning* dengan metode dan algoritma yang lainnya untuk diterapkan sebagai langkah peningkatan hasil akurasi.

## Daftar Pustaka

- [1] Kancherla and Mukamalla, "Early Lung Cancer Detection using Nucleus Segmentation based Features," *IEEE Symp. Comput. Intell. Bioinforma. Comput. Biol.*, pp. 91–95, 2013.
- [2] A. C. Society, "About Lung Cancer What Is Lung Cancer?," 2012. [Online]. Available: <http://www.cancer.org/Cancer/LungCancer-NonSmallCell/DetailedGuide/non-small-cell-lung-cancer-key-statistics>.
- [3] Redaksi WE Online, "Global Burden Cancer 2018: Kasus Kanker Paru-paru Indonesia Ada di Zona Serius," 2019. [Online]. Available: <https://www.wartaekonomi.co.id/read242598/global-burden-cancer-2018-kasus-kanker-paru-paru-indonesia-ada-di-zona-serius>. [Accessed: 10-Jun-2020].
- [4] Badan penelitian dan Pengembangan Kesehatan, *HASIL UTAMA RISKESDAS 2018*. Jakarta: Lembaga Penerbit Balitbangkes, 2018.
- [5] Komite penanggulangan kanker nasional, *Panduan Penatalaksanaan Kanker Paru*. Jakarta: Lembaga Penerbit Kemenkes RI, 2018.
- [6] F. Taher, N. Werghi, and H. Al-Ahmad, "Bayesian Classification and Artificial Neural Network Methods for Lung Cancer Early Diagnosis," *IEEE Int. Conf. Electron. Circuits, Syst. (ICECS 2012)*, pp. 773–776, 2012.
- [7] R. G.Naghdy, C. Todd, and E. Norahmawati, "Cervical Cancer Classification Using Gabor Filters," *IEEE First Int. Conf. Healthc. Informatics, Imaging Syst. Biol.*, pp. 194–198, 2011.
- [8] S. Kido, Y. Hirano, and N. Hashimoto, "Detection and Classification of Lung Abnormalities by Use of Convolutional Neural Network ( CNN ) and Regions with CNN Features ( R-CNN )," *Int. Work. Adv. Image Technol.*, pp. 1–4, 2018.
- [9] Journal medical, "What Is a Fine Needle Aspiration (FNA) Biopsy for Lung Cancer?," 2020. [Online]. Available: <https://www.verywellhealth.com/fine-needle-aspiration-biopsy-2249026>. [Accessed: 09-Oct-2020].
- [10] A. B. Frca, "Pleural fluid collections in critically ill patients," *Contin. Educ. Anaesth. Crit. Care Pain*, vol. 7, no. 1, pp. 10–14, 2007.
- [11] A. Mikołajczyk and M. Grochowski, "Data augmentation for improving deep learning in image classification problem," *Int. Interdiscip. PhD Work.*, no. August 2019, 2018.
- [12] W. Dong, "Fast Multi-Operator Image Resizing and Evaluation Fast Multi-Operator Image Resizing and Evaluation," no. December 2013, 2012.
- [13] M. Tan and Q. V Le, "EfficientNet : Rethinking Model Scaling for Convolutional Neural Networks," 2019.