

Klasifikasi Kondisi Pernapasan Berdasarkan Sinyal Radar Menggunakan *Convolutional Neural Network*

1st Muhammad Faqihna Fiddin
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia
mfiddinx@telkomuniversity.a.c.id

2nd R Yunendah Nur Fu'adah
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia
yunendah@telkomuniversity.a.c.id

3rd Edwar
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia
edwarm@telkomuniversity.a.c.id

Abstrak— Dalam dunia medis frekuensi pernapasan menjadi salah satu indikator awal yang dapat digunakan untuk mendiagnosa suatu gangguan yang berhubungan dengan sistem pernapasan. Pengukuran frekuensi pernapasan dapat dilakukan dengan alat bantu seperti radar. Radar adalah salah satu pendekatan yang bagus untuk mengukur frekuensi pernapasan manusia. Hasil pengukuran frekuensi pernapasan oleh radar masih berupa sinyal yang memerlukan penanganan lebih lanjut untuk mengetahui kondisi dari pernapasan seseorang. Maka dari itu, dibutuhkan sistem yang secara otomatis yang dapat mengklasifikasikan kondisi pernapasan seseorang dengan melihat sinyal radar tersebut. Pada penelitian ini bertujuan untuk merancang sistem klasifikasi kondisi pernapasan melalui sinyal radar dalam tiga kelas yaitu *low*, *normal*, dan *high*. Dataset yang diperoleh berasal dari *zenodo.org* dan berdasar jurnal dengan bentuk citra *scalogram*. Penelitian sistem klasifikasi kondisi pernapasan ini menggunakan *Convolutional Neural Network* (CNN) dengan arsitektur *MobileNet*. Parameter pengujian terbaik yang didapatkan adalah nilai *epoch* 100, nilai *batch size* 8, nilai *learning rate* 0,0001, dan dengan *optimizer Adam*. Hasil pengujian dengan parameter terbaik mendapatkan nilai akurasi 96,5% dengan nilai *loss* 0,104, nilai presisi 96,6%, nilai *recall* 96,4%, dan nilai *f1-score* 96,5%.

Kata kunci— pernapasan, klasifikasi, sinyal radar, *convolutional neural network*, *mobilenet*

I. PENDAHULUAN

Frekuensi pernapasan merupakan berapa jumlah seseorang melakukan pernapasan dalam rentang waktu satu menit serta biasanya ditandai dengan pergerakan dada mengembang dan mengempis. Dalam dunia medis frekuensi pernapasan menjadi salah satu indikator awal yang dapat digunakan untuk mendiagnosa suatu gangguan yang berhubungan dengan sistem pernapasan [1].

Pengukuran frekuensi pernapasan juga dapat dilakukan dengan alat bantu seperti radar. Dalam sistem radar, gerakan dinding dada manusia yang disebabkan oleh aktivitas pernapasan merupakan gerakan perpindahan kecil yang menghasilkan pergeseran *Doppler* dalam gelombang pantul. Oleh karena itu, radar adalah salah satu pendekatan yang bagus untuk mengukur frekuensi pernapasan manusia [2].

Hasil pengukuran frekuensi pernapasan oleh radar masih berupa sinyal yang memerlukan penanganan lebih lanjut untuk mengetahui kondisi dari pernapasan seseorang. Maka dari itu, dibutuhkan sistem yang secara otomatis yang dapat mengklasifikasikan kondisi pernapasan seseorang dengan melihat sinyal radar tersebut.

Terdapat beberapa penelitian serupa yang telah dilakukan sebelumnya. Penelitian oleh Rizky Ambarini, dkk. menggunakan *Single-Tone Doppler Radar* masih sebatas menghasilkan akuisi data dalam BPM (*breath per minute*) [2]. Penelitian oleh Umer Saeed, dkk. menggunakan algoritma *Residual Neural Network (ResNet)* mengklasifikasikan kondisi pernapasan kedalam dua kelas yaitu *normal* dan *abnormal*. Akurasi yang didapatkan adalah 90% [3]. Penelitian oleh Khushi Gupta, dkk. menggunakan algoritma *Convolutional Neural Network (CNN)* konvensional mengklasifikasikan kondisi pernapasan kedalam tiga kelas yaitu *low*, *normal*, dan *high*. Akurasi yang didapatkan adalah 87% [4].

Berdasarkan penelitian – penelitian sebelumnya, peneliti sebelumnya masih sebatas dalam proses akuisi serta menggunakan algoritma *ResNet* dan CNN konvensional serta menghasilkan akurasi yang belum mencapai diatas angka 90%. Maka dari itu, pada penelitian ini akan dibuat sistem yang mengklasifikasi kondisi pernapasan berdasar sinyal radar menggunakan *Convolutional Neural Network (CNN)* dengan arsitektur *MobileNet* mengklasifikasikan ke tiga kelas yaitu *low*, *normal*, dan *high*.

II. KAJIAN TEORI


A. Radar

Radio Detection and Ranging atau radar merupakan sistem elektromagnetik guna mendeteksi dan mengukur pada suatu objek yang bekerja dengan memancarkan gelombang elektromagnetik kemudian mengolah sinyal yang dipantulkan untuk mengetahui karakternya. Radar banyak diterapkan dalam berbagai skenario sebagai alat *remote sensing* jarak jauh salah satunya untuk bidang medis seperti pemantauan tanda vital, terutama untuk pernapasan [5-7].

Aktivitas pernapasan manusia dapat diketahui dari pergerakan dinding dada yang berhubungan dengan aktivitas menghirup dan menghembuskan napas. Dalam sistem radar,

gerakan dinding dada manusia yang disebabkan oleh aktivitas pernapasan merupakan gerakan perpindahan kecil yang menghasilkan pergeseran *Doppler* dalam gelombang pantul. Oleh karena itu, radar adalah pendekatan yang bagus untuk mendeteksi pemantauan pernapasan manusia [3].


Pola pernapasan selanjutnya dapat direpresentasikan melalui beberapa penyajian data salah satunya adalah *scalogram*. *Scalogram* adalah jenis bagan atau grafik yang digunakan untuk menampilkan frekuensi terhadap waktu.



GAMBAR 1
Scalogram pola pernapasan

B. Citra Digital


Citra adalah salah satu multimedia yang memiliki peran penting dalam menyajikan informasi secara visual [8]. Citra terbagi atas dua macam yaitu citra diskrit dan citra *continue*. Citra digital merupakan citra yang dihasilkan dari citra *continue* menggunakan proses digitalisasi. Biasanya citra digital berbentuk persegi atau persegi panjang memiliki nilai lebar dan tinggi tertentu [9]. Nilai *pixel* adalah nilai dari suatu citra yang selalu bernilai bilangan bulat. Gambar 2 berikut ini adalah representasi citra digital dalam dua dimensi.



GAMBAR 2
Citra digital dalam dua dimensi [10]

C. Citra RGB

Suatu *pixel* citra RGB tersusun dari tiga matriks yang merepresentasikan nilai warna merah, hijau, dan biru. Komponen dari tiap warna tersebut memiliki rentang nilai 0 hingga 255 atau 8 bit [10]. Kemungkinan yang dihasilkan dari nilai tersebut adalah terdapat total variasi warna yang berbeda 16.777.216 dari 256 x 256 x 256. Gambar 3 berikut ini merupakan contoh citra RGB.




GAMBAR 3.
Contoh citra RGB

D. Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan pengembangan dari *Multilayer Perceptron* (MLP). CNN termasuk macam dari *Machine Learning* pada kelompok *Supervised Learning*. Pada mulanya CNN dikenalkan dalam makalah ditulis oleh Yann LeCun et all pada tahun 1998 *Gradient-Based Learning Applied to Document Recognition* [11]. Versi pertama dari CNN adalah *LeNet* (berasal dari nama LeCun) dengan hasil dapat mengenali karakter tulisan tangan. Tapi *LeNet* masih sebatas optimal hanya dengan citra beresolusi rendah.

CNN adalah sebuah arsitektur yang bisa dilatih dan terdiri atas beberapa tahapan [12]. *Input* dan *output* tiap tahapan terdiri dari beberapa *array* disebut *feature map*. *Convolution layer*, *activation layer* dan *pooling layer* adalah tiga lapisan yang membentuk dari tiap tahapan CNN. Gambar 4 berikut adalah arsitektur dari *Convolutional Neural Network* (CNN).




GAMBAR 4.
Arsitektur Convolutional Neural Network [12]


E. Arsitektur MobileNet

MobileNet adalah arsitektur CNN yang dirancang guna memaksimalkan hasil akurasi dengan *resources* yang terbatas. Maka dari itu *MobileNet* mempunyai waktu komputasi, spesifikasi, dan rendah konsumsi energi sehingga bisa diaplikasikan secara mudah untuk aplikasi perangkat *mobile* [13]. *Depthwise Separable Convolution* adalah yang menjadi dasar dari arsitektur *MobileNet*. Pada *MobileNet standard convolution* digantikan menggunakan faktorisasi dengan memecah konvolusi menjadi dua *layer* yang terpisah yaitu *depthwise convolution* serta *pointwise convolution*. Gambar 5 berikut ini adalah blok diagram *standard convolution* dan *depthwise separable convolution*.

Depthwise convolution yang di *layer* pertama dengan menerapkan *single convolutional filter* tiap *input channel* akan melakukan *filtering* [13]. *Pointwise convolution* di *layer* kedua menggunakan kombinasi linier komputasi dari *input channel* dengan menerapkan konvolusi 1x1 berperan untuk membuat fitur baru. Gambar 6 berikut ini adalah blok *layer* tersusun dari *depthwise convolution* dan *pointwise convolution* yang disertai *batch normalization* dan aktivasi *rectified linier units* (ReLU).



GAMBAR 5.
Blok diagram standard convolution dan depthwise separable convolution. [13]



Gambar 6. Arsitektur *depthwise separable convolution* [13]

F. Optimizer

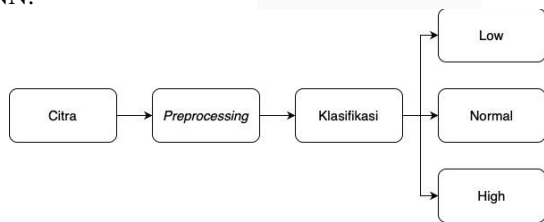
Optimizer adalah metode yang berguna untuk menemukan bobot, *learning rate* yang optimal, meminimalkan *loss*, serta memaksimalkan akurasi. *Optimizer* yang akan digunakan dalam pengujian adalah *optimizer Adam, Nadam, dan RMSprop*.

III. METODE

A. Diagram Sistem

Secara umum terdapat 3 bagian tahapan dari sistem kerja secara umum, yaitu citra, *preprocessing*, dan klasifikasi.

1. Citra : Sistem diberikan input data gambar scalogram radar pola pernapasan.
2. *Preprocessing* : Sistem melakukan tahap olah data pada citra dari *input* sebelumnya untuk proses normalisasi dan *resize*.
3. Klasifikasi : Sistem melakukan *training* model pada citra yang sebelumnya melalui *preprocessing* untuk dilakukan klasifikasi sesuai kelas yang ditentukan menggunakan CNN.




GAMBAR 7. Model Umum Sistem

B. Dataset

Penelitian menggunakan dataset *scalogram* radar pola pernapasan yang didapatkan dari *website Zenodo* mengacu pada jurnal berjudul “*Automatic Contact-Less Monitoring of Breathing Rate and Heart Rate Utilizing the Fusion of mmWave Radar and Camera Steering System*”. Dari jurnal tersebut dijelaskan bagaimana proses akuisisi data untuk mendapatkan data *scalogram* sinyal radar. Jenis radar yang digunakan adalah AWR1443 FMCW yang bekerja di rentang frekuensi 76 GHz sampai 81 GHz sehingga cocok untuk pembacaan gerak mikro. Pengambilan data melibatkan 12 subjek orang yang diminta untuk melakukan respirasi secara *low*, *normal*, dan *high*. [11]

Dataset yang didapatkan berupa citra berwarna yang memiliki ukuran *pixel* berformat **.png*. Dataset terbagi atas tiga kelas yaitu *low*, *normal*, dan *high*. Dataset awal sebanyak 345 citra berwarna terdiri 102 citra *low*, 121 citra *normal*, dan 122 citra *high*. Karena data citra masih memiliki jumlah yang sedikit maka akan dilakukan augmentasi. Proses augmentasi bertujuan meningkatkan dan menyeimbangkan jumlah data citra tiap kelas. Proses augmentasi yang dilakukan pada citra berwarna berupa *flip horizontal*. Dari proses augmentasi didapatkan jumlah data sebanyak 597 citra yang terdiri dari

194 citra *low*, 194 citra *normal*, dan 194 citra *high* serta 15 data tambahan untuk validasi. Gambar 3.2 berikut ini adalah contoh dari dataset tiap kelas.




Gambar 8. Contoh citra tiap kelas

C. Preprocessing

Preprocessing adalah tahapan olah citra sebelum ke tahap pelatihan sebagai *input*. *Preprocessing* akan dilakukan dengan dua tahap yaitu *resize* serta normalisasi. *Resize* adalah proses merubah ukuran dan resolusi pada citra agar seragam dengan ukuran yang sama. Tahap normalisasi bertujuan membuat agar rentang nilai yang sama dimiliki pada beberapa variabel citra.

D. Pelatihan Model

Penelitian ini akan menggunakan CNN dengan arsitektur *MobileNet* sebagai metode pelatihan model. Pelatihan model bertujuan supaya sistem bisa mengklasifikasikan citra sesuai kelas dari kondisi pernapasan yang sudah ditentukan. Dataset sebanyak 582 akan dibagi menjadi dua bagian, yaitu 80% untuk data *train* dan 20% untuk data *test*. Pelatihan model akan melalui dua tahapan, yaitu tahapan *training* dan tahapan *testing*. Tahapan *training* dilakukan untuk membuat model dengan memproses data *train*. Pada tahapan *training*, penelitian ini menggunakan metode pelatihan yang dibangun dengan set data latih yang dibagi menjadi dua bagian antara data latih dan data validasi.



GAMBAR 9. Blok diagram pelatihan model

E. Parameter Pengujian

Pengujian sistem akan dilakukan melalui perbandingan beberapa parameter sebanyak empat scenario pengujian,

yaitu pengujian *batch size*, pengujian *epoch*, pengujian *learning rate*, serta pengujian *optimizer*. Masing-masing skenario pengujian akan berkelanjutan sehingga hasil dari skenario pengujian sebelumnya akan diterapkan pada skenario pengujian selanjutnya. Hasil dari masing-masing skenario pengujian akan dianalisis guna mendapatkan sistem dengan performansi terbaik.

Berikut ini adalah skenario pengujian sistem pada penelitian ini :

1. Pengujian *Epoch*

Nilai *epoch* yang akan diuji dan dikomparasikan yaitu 25, 50, dan 100. Parameter pemisalan untuk nilai *batch size*, *learning rate*, dan *optimizer* akan digunakan untuk skenario pengujian tahap ini.

2. Pengujian *batch size*

Nilai *batch size* yang akan diuji dan dikomparasikan yaitu 8, 16, dan 32. Nilai *epoch* terbaik dari pengujian skenario sebelumnya akan digunakan pada skenario ini, serta digunakan parameter pemisalan untuk *learning rate* dan *optimizer*.

3. Pengujian *Learning rate*

Nilai *learning rate* yang akan diuji dan dikomparasikan yaitu 0.01, 0.001, dan 0.0001. Nilai *epoch* dan *batch size* terbaik dari skenario sebelumnya dan *optimizer* pemisalan akan digunakan pada skenario pengujian ini.

4. Pengujian *Optimizer*


Optimizer yang akan diuji dan dikomparasikan yaitu *Adam*, *Nadam*, dan *RMSprop*. Parameter terbaik dari pengujian *epoch*, *batch size*, dan *learning rate* dari skenario pengujian sebelumnya akan digunakan pada skenario pengujian ini.

IV. HASIL DAN PEMBAHASAN


A. Hasil Pengujian Skenario

Berikut adalah hasil dari pengujian skenario :


Epoch	Loss	Accuracy
25	0,151	91,40%
50	0,142	92,30%
100	0,112	93,10%




Batch Size	Loss	Accuracy
8	0,104	96,50%
16	0,168	94,80%
32	0,182	93,10%



Learning Rate	Loss	Accuracy
0,01	0,605	87,10%
0,001	0,228	94%
0,0001	0,104	96,50%



Optimizer	Loss	Accuracy
Adam	0,104	96,50%
Nadam	0,191	93,10%
RMSprop	0,566	94%



GAMBAR 10. Hasil skenario pengujian


B. Hasil Pengujian Parameter Terbaik

Dari hasil pengujian melalui keempat skenario sebelumnya, diperoleh parameter terbaik. Tabel berikut menunjukkan parameter terbaik untuk sistem.


TABEL 1

Hyperparameter	Parameter Terbaik
Epoch	100
Batch Size	8
Learning Rate	0,0001
Optimizer	Adam

Pengujian menggunakan parameter terbaik diperoleh nilai akurasi sebesar 96,5% dengan nilai *loss* sebesar 0,138. Gambar berikut menunjukkan grafik akurasi dan grafik *loss*.



GAMBAR 11. Grafik akurasi




GAMBAR 12. Grafik loss

Sistem pengujian dengan parameter terbaik performansi diukur dengan empat nilai, yaitu nilai presisi, *recall*, *f1-score*, dan *confusion matrix*. Tabel dan Gambar berikut menunjukkan hasil dari pengukuran performansi.

TABEL 11

Kelas	Presisi	Recall	F1-Score	Jumlah Citra
High	95,7	97,8	96,7	45
Low	100	97,4	98,7	38
Normal	94,1	94,1	94,1	34
Total	96,6	96,4	96,5	117



GAMBAR 13.
Confusion matrix

Tabel diatas memperlihatkan sistem pada pengujian memakai parameter terbaik dengan nilai presisi sebesar 96,6%, *recall* 96,4%, dan *f1-score* 96,5%. Gambar 4.7 memperlihatkan dari 117 total citra dari data tes yang digunakan, ada 113 citra yang secara benar terdeteksi sesuai yaitu 44 citra kelas *high*, 37 citra kelas *low*, dan 32 citra kelas normal.

V. KESIMPULAN

Dari hasil pengujian dan analisa empat skenario yang telah dilakukan, maka disimpulkan Sistem yang telah dirancang menggunakan *Convolutional Neural Network* (CNN) dengan arsitektur *MobileNet* dapat mengklasifikasikan kondisi penerapan terhadap citra *scalogram* radar ke dalam tiga kelas yaitu *low*, normal, dan *high*. Pengukuran performansi sistem dengan hasil terbaik didasarkan pada beberapa parameter, yaitu akurasi, *loss*, *recall*, *f1-score*, dan *confusion matrix*. Pengujian terbaik diperoleh menggunakan parameter pengujian nilai *epoch* 100, batch size 8, *learning rate* 0,0001, dan dengan *optimizer Adam*. Hasil yang diperoleh adalah akurasi sebesar 96,5% dengan *loss* 0,104, presisi 96,6%, *recall* 96,4%, dan *f1-score* 96,5%.

REFERENSI

- [1] Shan He*, Zixiong Han, Cristóvão Iglesias, Varun Mehta and Miodrag Bolic Article, "A Real-Time Respiration Monitoring and Classification System Using a Depth Camera and Radars"
- [2] Ambarini R, Pramudita A A, Ali E and Setiawan A D 2018 Single-tone doppler radar system for human respiratory monitoring Int. Conf. Electr. Eng. Comput. Sci. Informatics 2018-October 571–5
- [3] U. Saeed, S. Y. Shah, A. A. Alotaibi, and T. Althobaiti, "Portable UWB RADAR Sensing System for Transforming Subtle Chest Movement Into Actionable Micro-Doppler Signatures to Extract Respiratory Rate Exploiting ResNet Algorithm," Proceedings of tge IEEE, vol.21, no. 20
- [4] K. Gupta, S. M. B., S. J, O. J. Pandey and L. R. Cenkeramaddi, "Automatic Contact-Less Monitoring of Breathing Rate and Heart Rate Utilizing the Fusion of mmWave Radar and Camera Steering System," in IEEE Sensors Journal, vol. 22, no. 22, pp. 22179-22191, 15 Nov.15, 2022, doi: 10.1109/JSEN.2022.3210256.
- [5] M. Leib, W. Menzel, B. Schleicher and H. Schumacher, "Vital signs monitoring with a UWB radar based on a correlation receiver," Proceedings of the Fourth European Conference on Antennas and Propagation, Barcelona, Spain, 2010, pp. 1-5.
- [6] C. H. Hsieh, Y. F. Chiu, Y. H. Shen, T. S. Chu and Y. H. Huang, "A UWB Radar Signal Processing Platform for Real-Time Human Respiratory Feature Extraction Based on Four-Segment Linear Waveform Model," in IEEE Transactions on Biomedical Circuits and Systems, vol. 10, no. 1, Feb. 2016, pp. 219-230.
- [7] T. Kiuru et al., "Movement and respiration detection using statistical properties of the FMCW radar signal," 2016 Global Symposium on Millimeter Waves (GSMM) and ESA Workshop on Millimetre-Wave Technology and Applications, Espoo, 2016, pp. 1-4.
- [8] T. Zebua and E. Ndruru, "Pengamanan Citra Digital Berdasarkan Modifikasi Algoritma RC4," Jurnal Teknologi Informasi dan Ilmu Komputer", vol. 4, no.4, p. 275, Dec. 2017, doi: 10.25126/jtiik. 201744474.
- [9] M. Aynurrohmah and A. Sunyoto, "PENGHITUNG JUMLAH MOBIL MENGGUNAKAN PENGOLAHAN CITRA DIGITAL DENGAN INPUT VIDEO DIGITAL," Jurnal Dasi, vol. 12, no. 3, 2011.
- [10] R. D. Kusumanto and A. N. Tomponu, "PENGOLAHAN CITRA DIGITAL UNTUK MENDETEKSI OBYEK MENGGUNAKAN PENGOLAHAN WARNA MODEL NORMALISASI RGB," 2011.
- [11] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," Proceedings of the IEEE, vol.86, no. 11, pp. 2278-2324, 1998, doi: 10.1109/5.726791.
- [12] E. N. Arrofiqoh and H. Harintaka, "IMPLEMENTASI METODE CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI TANAMAN PADA CITRA RESOLUSI TINGGI," GEOMATIKA, vol. 24, no. 2, p. 61, Nov. 2018, doi: 10.24895/jig. 2018.24-2.810.
- [13] A. G. Howard et al., "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications," Apr. 2017.