

# Pengaruh Data Balancing Pada Klasifikasi *Pneumonia* Menggunakan VGG16

MUHAMMAD HARITS RASYID RAMADHAN<sup>1\*</sup>, YUSUP MIFTAHUDDIN<sup>1</sup>

<sup>1</sup>Program Studi Informatika, Institut Teknologi Nasional Bandung  
Email: rasyid.haris@mhs.itenas.ac.id

Received 27 01 2023 | Revised 03 02 2023 | Accepted 03 02 2023

## ABSTRAK

*Dengan berkembangnya teknologi khususnya pada bidang artificial intelligence (kecerdasan buatan), kini penyakit dapat diidentifikasi melalui gambar atau citra. Salah satunya adalah penyakit pneumonia dapat diklasifikasikan dengan menggunakan citra x-ray paru-paru. Namun permasalahan yang masih menjadi halangan untuk mencapai hasil klasifikasi yang baik adalah banyaknya dataset diluar sana yang tidak mempunyai jumlah data seimbang. Hal ini akan mengakibatkan hasil klasifikasi yang kecenderungan terhadap kelas yang memiliki jumlah data lebih banyak. Salah satu cara untuk mengatasi masalah tersebut adalah dengan melakukan data balancing terhadap dataset yang digunakan, salah satunya adalah Random Oversampling (ROS). Pada penelitian ini diusulkan pengujian antara model VGG16 tanpa data balancing dengan VGG16 dengan data balancing. Hasil menunjukkan bahwa model VGG16 tanpa data balancing memiliki rata-rata akurasi sebesar 73% dengan mengalami banyak klasifikasi false positive, sedangkan model VGG16 dengan data balancing berhasil menurunkan tingkat klasifikasi false positive dan hasil akurasi rata-rata 83%.*

**Kata kunci:** Data Balancing, Pneumonia, VGG16, Kecerdasan Buatan

## ABSTRACT

*With the development of technology, especially in the field of artificial intelligence, now diseases can be identified through pictures or images. One of them is that pneumonia can be classified using x-ray images of the lungs. However, the problem that is still an obstacle to achieving good classification results is the large number of datasets out there that do not have a balanced amount of data. This will result in classification results that tend towards classes that have more data. One way to overcome this problem is to perform data balancing on the dataset used, one of which is Random Oversampling (ROS). In this study, it is proposed to test the VGG16 model without data balancing and VGG16 with data balancing. The results show that the VGG16 model without data balancing has an average accuracy of 73% by experiencing many false positive classifications, while the VGG16 model with data balancing has succeeded in reducing the false positive classification rate and the average accuracy results are 83%.*

**Keywords:** Data Balancing, Pneumonia, VGG16, Artificial Intelligence

## 1. PENDAHULUAN

Berdasarkan angka kematian dibawah 5 tahun (*under-5 mortality rate/U5MR*), pneumonia adalah penyebab kematian utama di berbagai negara dengan angka kematian yang sangat tinggi (Liu et al., 2016). Menurut penelitian yang dilakukan oleh salah satu LSM di India, penderita pneumonia dapat diselamatkan jika tindakan yang tepat dapat dilakukan. Salah satunya adalah dengan diagnosis dini yang akurat dan pengobatan. Saat ini beberapa metode untuk mendiagnosa pneumonia adalah tes darah, rontgen dada, CT scan, dan bronkoskopi (Habib et al., 2020). Namun sayangnya kekurangan pada metode tersebut untuk mendiagnosa pneumonia adalah membutuhkan waktu yang lama bagi tenaga medis untuk mendapatkan hasil dari tes tersebut (Saputra & Krismono, 2020).

Dengan kemajuan teknologi di bidang kecerdasan buatan khususnya pada *machine learning* dan *deep learning*. Kini penyakit dapat diidentifikasi melalui gambar atau citra. Teknologi ini dapat membuat prediksi dan deteksi penyakit menjadi lebih mudah, lebih murah, dan lebih mudah diakses (Habib et al., 2020). *Convolutional Neural Network* (CNN) adalah salah satu metode *deep learning* yang dapat digunakan untuk deteksi dan mengenali objek pada suatu gambar atau citra. CNN dapat mengurangi sejumlah besar parameter independen dan menangani distorsi gambar seperti translasi, rotasi, dan penskalaan yang memungkinkan CNN untuk mengklasifikasi citra dengan tingkat akurasi yang tinggi (Saputra & Krismono, 2020).

Untuk mendapatkan klasifikasi penyakit yang akurat, *dataset* yang dipakai harus memiliki jumlah data antar kelas yang setara (*balance*). Karena jika jumlah data antar kelas berada dalam kondisi yang tidak setara, sehingga akan mengakibatkan model yang lebih condong terhadap kelas yang memiliki data lebih banyak. Masalah ini disebut sebagai *data imbalance*, dalam keadaan seperti itu meskipun akurasi yang diperoleh akan tinggi, tetapi hasil dari skor evaluasi seperti *precision*, *recall*, dan *F1-score* akan tidak akan terlihat baik (Mohammed et al., 2020).

Salah satu cara untuk mengatasi permasalahan pada *data imbalance* adalah dengan melakukan *data balancing* pada *dataset* yang akan dipakai. *Random Oversampling* (ROS) dan *Random Undersampling* (RUS) adalah salah satu teknik *data balancing*. Cara kerja ROS adalah dengan meningkatkan jumlah data pada *minority class* sampai jumlah data nya menyeimbangi *majority class*, sedangkan cara kerja RUS adalah dengan mengurangi jumlah data pada *majority class* sampai jumlah data nya menyeimbangi *minority class* (Somasundaram & Reddy, 2016). Penelitian yang dilakukan oleh (Ahnafi et al., 2020) pada klasifikasi pneumonia menggunakan ResNet dan ROS menghasilkan akurasi sebesar 89% dengan parameter *epoch* 15 dan *batch size* 64.

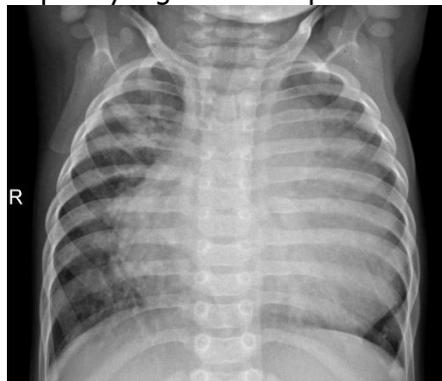
Penelitian ini akan menggunakan arsitektur *Visual Geometry Group 16* (VGG16) sebagai model CNN dan menggunakan ROS serta RUS untuk melakukan *data balancing* pada *dataset* yang akan dipakai, kemudian mengukur tingkat akurasi yang diperoleh. *Dataset* yang akan digunakan diperoleh dari kaggle.com dengan jumlah data sebesar 5.856 citra berupa citra *x-ray*.

## 2. METODE PENELITIAN

### 2.1 Pneumonia

Pneumonia adalah penyakit paru-paru di mana kantung udara terinfeksi oleh berbagai penyebab mikroorganisme, termasuk jamur bakteri, dan virus pneumonia. Salah satu cara

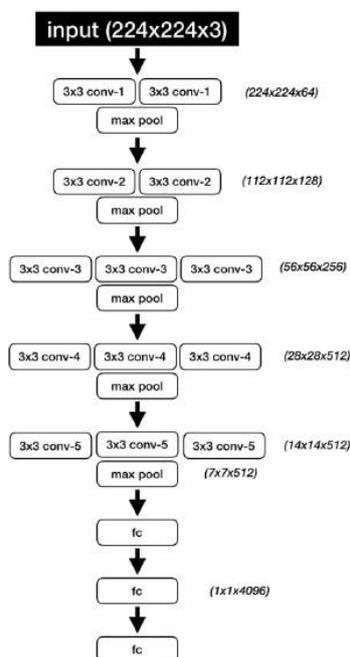
untuk mendiagnosa pneumonia adalah dengan cara rontgen atau *x-ray* (Wati et al., 2020). Dari hasil rontgen atau *x-ray* dapat terlihat infiltrat atau bayangan putih (bercak) pada paru-paru yang terbentuk karena cairan radang (Dewiningsih, 2018). Gambar 1 merupakan contoh rontgen atau *x-ray* paru-paru yang terinfeksi pneumonia.



Gambar 1. X-Ray Paru-Paru Pneumonia

## 2.2 Visual Geometry Group 16 (VGG16)

Pada 2014, K. Simonyan dan A. Zisserman mengembangkan model CNN bernama *Visual Geometry Group 16* (VGG16). Model ini memiliki 16 lapisan *convolutional* dengan ukuran kernel 3x3, 5 lapisan *max pooling*, dan 3 lapisan terakhir *fully connected layers* (fc) (Ayan & Ünver, 2019). Gambar 2 menunjukkan arsitektur dari model VGG16.



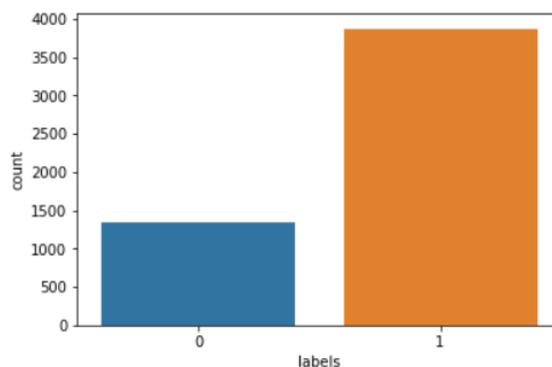
Gambar 2. Arsitektur Model VGG16 (Swastika, 2020)

Gambar *input* untuk arsitektur model VGG16 adalah gambar dengan ukuran 224x224 piksel dengan 3 *channel* RGB. Dalam konvolusi 1 (*conv-1*) diberikan 64 filter dengan kernel 3x3 diikuti oleh fungsi aktivasi ReLU dan dilakukan *max pooling* untuk mengurangi dimensi spasial. Kemudian konvolusi 2 memiliki 128 filter, konvolusi 3 memiliki 256 filter, konvolusi 4 dan 5 memiliki 512 filter. Lapisan terakhir yaitu 3 lapisan *fully connected layer* (fc) dengan aktivasi ReLU dan *output layer* (Swastika, 2020).

### 2.3 Data Imbalance

*Data imbalance* adalah kondisi dimana suatu kelas memiliki jumlah data yang sangat berbeda dibandingkan kelas lainnya. Kelas dengan data terbanyak sering disebut sebagai kelas mayoritas dan kelas dengan data paling sedikit disebut sebagai kelas minoritas (Akbar & Hayaty, 2020). Kondisi tersebut akan berpengaruh pada proses klasifikasi data yang akan dilakukan untuk menentukan kelas suatu data. Jika kondisi tersebut terjadi maka akan terjadi kecenderungan kelas data kepada kelas yang memiliki data lebih banyak (kelas mayoritas) (Utomo et al., 2007). Pada penelitian ini kelas mayoritas nya adalah kelas pneumonia dan kelas minoritas nya adalah kelas normal. Gambar 3 menunjukkan ketidakseimbangan pada *dataset* yang digunakan.

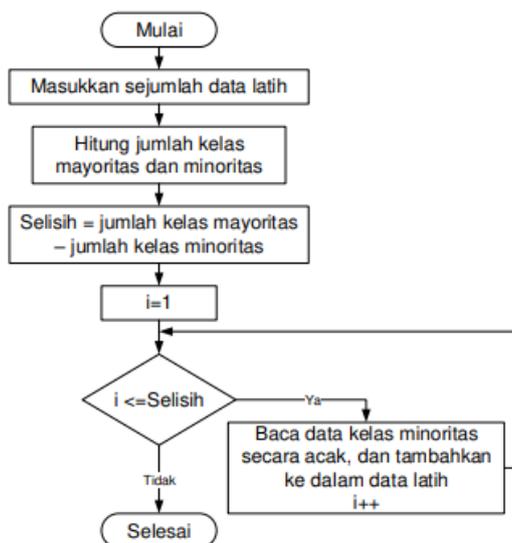
{0: 'No Pneumonia', 1: 'Yes Pneumonia'}



Gambar 3. Ketidakseimbangan *Dataset*

### 2.4 Random Oversampling (ROS)

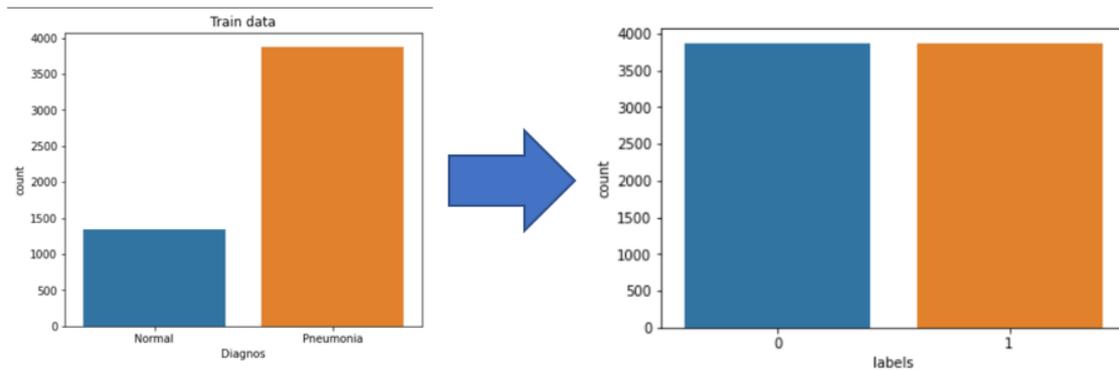
Untuk menangani kondisi *data imbalance* dapat dilakukan metode *data balancing* salah satunya adalah *Random Oversampling* (ROS). Gambar 4 menunjukkan algoritma dari ROS.



Gambar 4. Algoritma *Random Oversampling* (ROS)

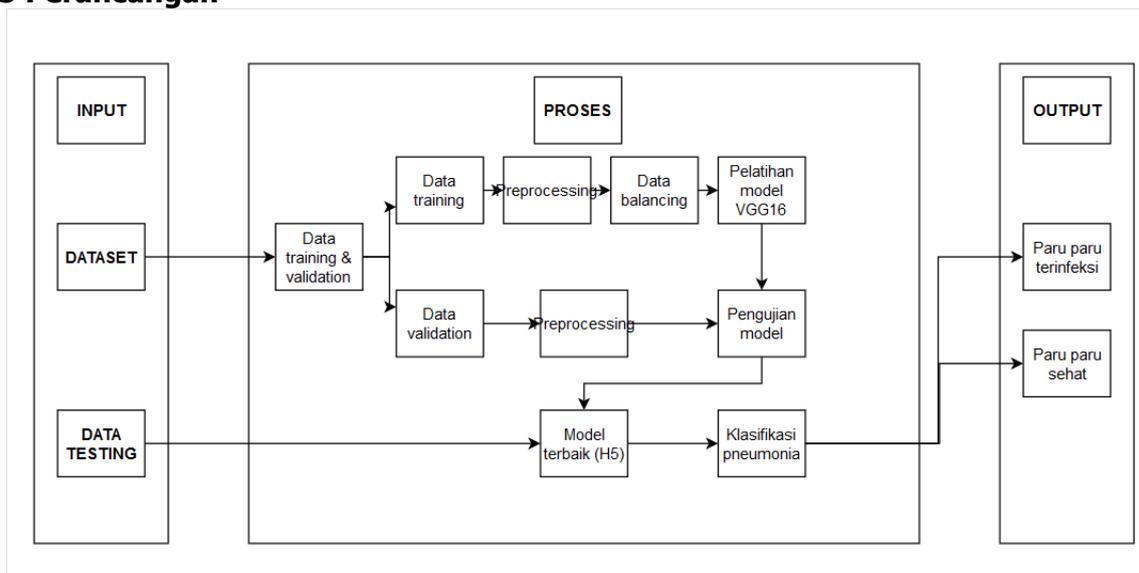
Cara kerja ROS adalah meningkatkan citra pada kelas minoritas dengan menduplikasi secara acak kemudian ditambahkan kedalam data latih sampai jumlahnya seimbang dengan

kelas mayoritas yaitu kelas pneumonia. Pertama-tama ROS akan membaca keseluruhan *dataset* yang digunakan, kemudian menghitung jumlah kelas mayoritas dan minoritas dan mengetahui selisih dari jumlah data antar kelas. Setelah itu ROS akan memperbanyak citra pada kelas minoritas dengan cara menduplikasi citra sampai jumlah sama dengan kelas mayoritas (**Saifudin et al., 2015**). Gambar 5 merupakan hasil dari *data balancing* pada *dataset* menggunakan ROS



**Gambar 5. Data Balancing Pada Dataset Menggunakan ROS**

## 2.5 Perancangan



**Gambar 6. Perancangan Penelitian**

Gambar 6 diatas merupakan rancangan penelitian yang akan dilakukan, penjelasan dari gambar diatas dijelaskan pada poin-poin seperti berikut:

- Dataset* yang sudah diperoleh dimuat kedalam model yang akan diuji.
- Pada proses *training*, dilakukan terlebih dahulu *preprocessing* pada *dataset*.
- Kemudian dilakukan proses *data balancing* menggunakan ROS, sehingga menghasilkan model VGG16 ROS.
- Model kemudian dilatih dengan parameter *epoch* 20 & 50, *learning rate* 0,1 & 0,01, *batch size* 32 & 64, lalu *optimizer Adam & Adamax*. Parameter tersebut dipilih dikarenakan penelitian yang dilakukan oleh (**Ahnafi et al., 2020**) menggunakan parameter *epoch* 15 dan *batch size* 64.

- e. Setelah melalui proses *training* maka model akan diuji menggunakan *data testing*.
- f. Model yang memiliki akurasi lebih baik pada saat pengujian akan digunakan untuk melakukan klasifikasi

### 3. HASIL DAN PEMBAHASAN

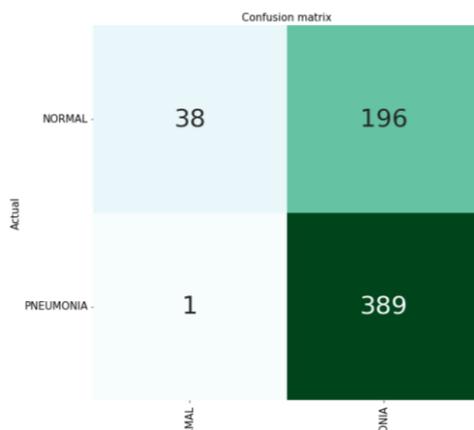
#### 3.1 Hasil *Training* Model

Pengujian dilakukan dengan melakukan perbandingan model VGG16 dengan *data balancing* dan model VGG16 tanpa *data balancing*. Gambar 7 menunjukkan hasil akurasi yang diperoleh model VGG16 tanpa *data balancing* dengan parameter *epoch* 20, *learning rate* 0,1, *batch size* 32, dan *optimizer Adamax* adalah sebesar 68%.

	precision	recall	f1-score	support
0	0.97	0.16	0.28	234
1	0.66	1.00	0.80	390
accuracy			0.68	624
macro avg	0.82	0.58	0.54	624
weighted avg	0.78	0.68	0.60	624

**Gambar 7. Hasil Akurasi VGG16 Tanpa *Data Balancing***

Kemudian, hasil dari *testing* yang didapat oleh model VGG16 tanpa *data balancing* mengalami kecenderungan terhadap kelas yang memiliki jumlah data lebih banyak yaitu kelas pneumonia. Sehingga hasil yang didapat mengalami *false positive* sebanyak 196 data atau 31,41% data dari total 624 data *testing*. Gambar 8 menunjukkan hasil *confusion matrix* model VGG16 tanpa *data balancing*.



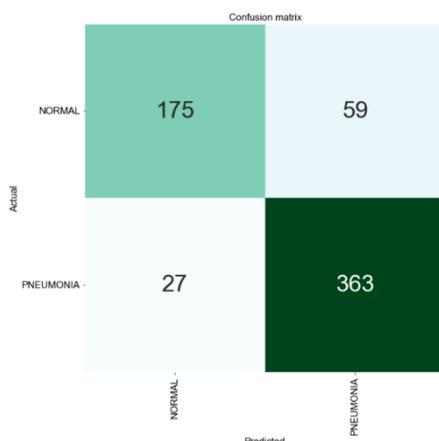
**Gambar 8. *Confusion Matrix* Model VGG16 Tanpa *Data Balancing***

Lalu Gambar 9 menunjukkan hasil akurasi yang diperoleh model VGG16 dengan *data balancing* dengan parameter *epoch* 20, *learning rate* 0,1, *batch size* 32, dan *optimizer Adamax* adalah sebesar 86%.

Accuracy: 0.8621794871794872				
Global F1 Score: 0.8621794871794872				
	Precision	Recall	F-Score	Support
NORMAL	0.866337	0.747863	0.802752	234.0
PNEUMONIA	0.860190	0.930769	0.894089	390.0

**Gambar 9. Hasil Akurasi VGG16 Dengan Data Balancing**

Hasil dari *testing* yang didapat oleh model VGG16 dengan *data balancing* mampu mengurangi tingkat *false positive* pada model VGG16 tanpa *data balancing* dengan jumlah 59 atau 9,45% data dari 624 total data *testing*. Gambar 10 menunjukkan hasil *confusion matrix* model VGG16 dengan *data balancing*.



**Gambar 10. Confusion Matrix Model VGG16 Dengan Data Balancing**

Pengujian juga dilakukan dengan mengubah-ubah parameter seperti yang dijelaskan pada subbab 2.5 poin d. Tabel 1 menunjukkan hasil seluruh pengujian model VGG16 tanpa *data balancing*.

**Tabel 1. Hasil Pengujian VGG16 Tanpa Data Balancing**

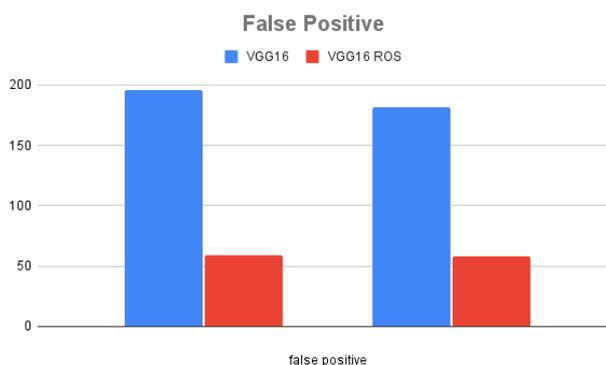
<i>Epoch</i>	<i>Batch Size</i>	<i>Learning Rate</i>	<i>Optimizer</i>	<i>Akurasi</i>
20	32	0.01	Adam	0.7
20	32	0.01	Adamax	0.65
20	32	0.1	Adam	0.72
20	32	0.1	Adamax	0.68
20	64	0.01	Adam	0.82
20	64	0.01	Adamax	0.71
20	64	0.1	Adam	0.83
20	64	0.1	Adamax	0.68
50	32	0.01	Adam	0.71
50	32	0.01	Adamax	0.71
50	32	0.1	Adam	0.84
50	32	0.1	Adamax	0.71
50	64	0.01	Adam	0.72
50	64	0.01	Adamax	0.66
50	64	0.1	Adam	0.7
50	64	0.1	Adamax	0.8

Dari 16 pengujian yang dilakukan, model VGG16 tanpa *data balancing* memiliki rata-rata akurasi sebesar 73%. Kemudian Tabel 2 menunjukkan hasil seluruh pengujian model VGG16 dengan *data balancing*.

**Tabel 2. Hasil Pengujian VGG16 Dengan *Data Balancing***

<i>Epoch</i>	<i>Batch Size</i>	<i>Learning Rate</i>	<i>Optimizer</i>	<i>Akurasi</i>
20	32	0.01	Adam	0.88
20	32	0.01	Adamax	0.87
20	32	0.1	Adam	0.88
20	32	0.1	Adamax	0.86
20	64	0.01	Adam	0.85
20	64	0.01	Adamax	0.86
20	64	0.1	Adam	0.88
20	64	0.1	Adamax	0.86
50	32	0.01	Adam	0.87
50	32	0.01	Adamax	0.86
50	32	0.1	Adam	0.89
50	32	0.1	Adamax	0.87
50	64	0.01	Adam	0.88
50	64	0.01	Adamax	0.87
50	64	0.1	Adam	0.87
50	64	0.1	Adamax	0.85

Dari 16 pengujian yang dilakukan, model VGG16 dengan *data balancing* memiliki rata-rata akurasi sebesar 87%. Dari 32 total pengujian, didapatkan rata-rata tingkat *false positive* antar model dimana model VGG16 tanpa *data balancing* memiliki rata-rata 189,25 data sedangkan model VGG16 dengan *data balancing* memiliki rata-rata 59,62 data. Gambar 11 menunjukkan tingkat *false positive* yang terjadi pada antar model.



**Gambar 11. Tingkat *False Positive***

### 3.2 Pengujian Pada Data *Testing*

Setelah dilakukan proses *training* maka dilakukan pengujian pada data *testing*, Tabel 3 menunjukkan pengujian oleh model VGG16 tanpa *data balancing*.

**Tabel 3. Pengujian Data *Testing* VGG16 Tanpa *Data Balancing***

Model	Gambar	Kelas Benar	Klasifikasi	Probabilitas
VGG16		NORMAL	Pneumonia	0.9903605
VGG16		NORMAL	Pneumonia	0.9862206
VGG16		NORMAL	Pneumonia	0.9200637
VGG16		PNEUMONIA	Pneumonia	0.9943499
VGG16		PNEUMONIA	Pneumonia	0.9999999
VGG16		PNEUMONIA	Pneumonia	0.9999976

Dapat dilihat dari hasil pengujian diatas, model VGG16 tanpa *data balancing* kecenderungan terhadap kelas pneumonia sehingga mengakibatkan model tersebut mengalami *false positive*. Kemudian Tabel 4 menunjukkan pengujian oleh model VGG16 dengan *data balancing*.

**Tabel 4. Pengujian Data *Testing* VGG16 Dengan *Data Balancing***

Model	Gambar	Kelas Benar	Klasifikasi	Probabilitas
VGG16 ROS		NORMAL	Normal	0.5998815
VGG16 ROS		NORMAL	Normal	0.70249003

Model	Gambar	Kelas Benar	Klasifikasi	Probabilitas
VGG16 ROS		NORMAL	Normal	0.6429624
VGG16 ROS		PNEUMONIA	Pneumonia	0.68794936
VGG16 ROS		PNEUMONIA	Pneumonia	0.95004094
VGG16 ROS		PNEUMONIA	Pneumonia	0.97120184

Dapat dilihat dari hasil pengujian diatas, model VGG16 dengan *data balancing* berhasil mengklasifikasi 6 data dengan benar dan berhasil mengurangi tingkat *false positive* pada model sebelumnya.

#### 4. KESIMPULAN

Pada penelitian ini telah diimplementasikannya salah satu metode dari *data balancing* yaitu *Random Oversampling* (ROS) pada model VGG16. Hasil dari dilakukannya *data balancing* mempengaruhi hasil akurasi dan klasifikasi terhadap citra paru-paru, dimana model VGG16 tanpa *data balancing* banyak mengalami klasifikasi *false positive* pada saat pengujian dan hasil akurasi yang didapat adalah rata-rata 73% dari 16 pengujian. Sedangkan model VGG16 dengan *data balancing* mampu mengurangi klasifikasi *false positive* pada saat pengujian dan hasil akurasi yang didapat adalah rata-rata 83%.

## DAFTAR PUSTAKA

- Ahnafi, A. H., Arifianto, A., & Ramadhani, K. N. (2020). Pneumonia Classification from X-ray Images using Residual Neural Network. *Ind. Journal on Computing*, 5(September), 43–54. <https://doi.org/10.21108/indojc.2020.5.2.454>
- Akbar, K., & Hayaty, M. (2020). Data Balancing untuk Mengatasi Imbalance Dataset pada Prediksi Produksi Padi. *Jurnal Ilmiah Intech: Information Technology Journal of UMUS*, 2(02). <https://doi.org/10.46772/intech.v2i02.283>
- Ayan, E., & Ünver, H. M. (2019). Diagnosis of pneumonia from chest X-ray images using deep learning. *2019 Scientific Meeting on Electrical-Electronics and Biomedical Engineering and Computer Science, EBBT 2019*, 0–4. <https://doi.org/10.1109/EBBT.2019.8741582>
- Dewiningsih. (2018). Faktor Lingkungan dan Perilaku Kejadian Pneumonia Balita Usia 12-59 Bulan. *HIGEIA (Journal of Public Health Research and Development)*, 2(3), 453–464. <https://journal.unnes.ac.id/sju/index.php/higeia/article/view/23512>
- Habib, N., Hasan, M. M., Reza, M. M., & Rahman, M. M. (2020). Ensemble of CheXNet and VGG-19 Feature Extractor with Random Forest Classifier for Pediatric Pneumonia Detection. *SN Computer Science*, 1(6), 1–9. <https://doi.org/10.1007/s42979-020-00373-y>
- Liu, L., Oza, S., Hogan, D., Chu, Y., Perin, J., Zhu, J., Lawn, J. E., Cousens, S., Mathers, C., & Black, R. E. (2016). Global, regional, and national causes of under-5 mortality in 2000–15: an updated systematic analysis with implications for the Sustainable Development Goals. *The Lancet*, 388(10063), 3027–3035. [https://doi.org/10.1016/S0140-6736\(16\)31593-8](https://doi.org/10.1016/S0140-6736(16)31593-8)
- Mohammed, R., Rawashdeh, J., & Abdullah, M. (2020). Machine Learning with Oversampling and Undersampling Techniques: Overview Study and Experimental Results. *2020 11th International Conference on Information and Communication Systems, ICICS 2020*, 243–248. <https://doi.org/10.1109/ICICS49469.2020.239556>
- Saifudin, A., Pamulang, U., Wahono, R. S., Dian, U., & Semarang, N. (2015). Pendekatan Level Data untuk Menangani Ketidakseimbangan Kelas pada Prediksi Cacat Software. *Journal of Software Engineering*, 1(2), 76–85.
- Saputra, A. E., & Krismono, B. (2020). *Klasifikasi Penderita Pneumonia Berdasarkan Citra Chest X-Ray Menggunakan Metode Convolutional Neural Network pada Android*. 1–13.
- Somasundaram, A., & Reddy, U. S. (2016). Data Imbalance: Effects and Solutions for Classification of Large and Highly Imbalanced Data. *Proceedings of 1st International Conference on Research in Engineering, Computers and Technology (ICRECT 2016), November*, 28–34.
- Swastika, W. (2020). Studi Awal Deteksi COVID-19 Menggunakan Citra CT Berbasis Deep Learning. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 7(3), 629. <https://doi.org/10.25126/jtiik.2020733399>
- Utomo, S. S., Cahyanto, T. A., & Prakoso, B. H. (2007). *Penggunaan Algoritma Random Over Sampling Untuk Mengatasi Masalah Imbalance Data Pada Klasifikasi Gizi Balita*. 1–9.
- Wati, R. A., Irsyad, H., & Rivan, M. E. Al. (2020). Klasifikasi Pneumonia Menggunakan Metode Support Vector Machine. *Jurnal Algoritme*, 1(1), 21–32. <https://jurnal.mdp.ac.id/index.php/algoritme/article/view/429/171>