

Teknik *Random Undersampling* untuk Mengatasi Ketidakseimbangan Kelas pada *CT Scan* Kista Ginjal

Random Undersampling Technique to Overcome Class Imbalance in Kidney Cyst CT Scan

Irfan Surya Ramadhan¹, Abu Salam²

^{1,2}Universitas Dian Nuswantoro/Teknik Informatika, Universitas Dian Nuswantoro

E-mail: ¹111202012863@mhs.dinus.ac.id, ²abu.salam@dsn.dinus.ac.id

Abstrak

Kista ginjal adalah pertumbuhan jaringan berbentuk kantong yang berisi cairan pada sekitar ginjal. Seringkali kista ginjal tidak menimbulkan gejala, sehingga memerlukan pantauan reguler dokter. Dokter dapat melakukan pemeriksaan dan merencanakan tindakan penelitian lebih lanjut. Penelitian ini fokus pada model klasifikasi kista menggunakan model Deep Learning dengan arsitektur Convolution Neural Network (CNN), jenis jaringan syaraf tiruan untuk analisis gambar CT scan kista ginjal. Selain itu, penggunaan teknik pre-processing untuk meningkatkan performa model dengan memperbanyak variasi data. Dalam membuat model klasifikasi perlu memperhatikan pemahaman data, tingkat interpretabilitas model, dan penanganan overfitting. Overfitting terjadi ketika model terlalu fokus pada data latih, sehingga tidak dapat memproses data uji dengan baik. Solusi untuk menangani masalah distribusi kelas adalah dengan menyeimbangkan kelas (resampling). Resampling dibagi menjadi dua jenis yaitu, undersampling dan oversampling. Undersampling merupakan metode sampling secara acak memilih di kelas mayoritas dan menambahkannya di kelas minoritas. Dan oversampling merupakan menggandakan sampel di kelas minoritas secara acak. Pada hasil pengujian model yang dilakukan dapat ditarik kesimpulan bahwa penggunaan teknik undersampling RUS memiliki tingkat akurasi tertinggi dengan nilai 30,82% untuk klasifikasi kista ginjal pada dataset tidak seimbang.

Kata kunci: *Kista Ginjal, Deep Learning, CNN, Random Undersampling, CT Scan*

Abstract

Kidney cyst is a sac-shaped growth of tissue that contains fluid around the kidney. Sometimes kidney cysts do not cause symptoms, so they require regular doctor monitoring. The doctor can carry out examinations and plan further research actions. This research focuses on cyst classification models using a Deep Learning model with a Convolution Neural Network (CNN) architecture, a type of artificial neural network for analyzing CTscan image of kidney cysts. In addition, the use of pre-processing techniques to improve model performance by increasing data variation. When creating a classification model, it is necessary to pay attention to understanding the data, the level of model interpretability, and handling overfitting. Overfitting occurs when the model focuses too much on the training data, so it cannot process the test data properly. The solution to dealing with class distribution problems is class balancing (resampling). Resampling is divided into two types, namely, undersampling and oversampling. Undersampling is a sampling method that randomly selects the majority class and adds the minority class. And oversampling is a random doubling of the sample in the minority class. From the results of the model testing carried out, it can be concluded that the use of the RUS undersampling technique has the highest level of accuracy with a value of 30.82% for the classification of kidney cysts in an unbalanced dataset.

Keywords: *Kidney Cyst, Deep Learning, CNN, Random Undersampling, CT Scan*

1. PENDAHULUAN

Di dalam tubuh manusia terdapat 2 ginjal yang berbentuk seperti kacang, yang terletak pada bagian bawah tulang rusuk dan dekat bagian tengah punggung. Fungsi utama ginjal adalah menyaring hasil metabolisme tubuh yang berada dalam darah dan mengeluarkan dalam bentuk urine. Namun, karena beberapa faktor tertentu menyebabkan bagian ginjal tersumbat, hal ini akhirnya membuat urine menggenang dan membentuk kantung (*divertikulum*). Kemudian kantung tersebut akan terlepas, dan menjadi kista. Kista ginjal adalah pertumbuhan jaringan abnormal berbentuk kantong yang berisi cairan pada sekitar ginjal. Kista ginjal dapat muncul pada satu atau kedua ginjal, serta memiliki variasi ukuran dari yang sangat kecil hingga besar [1]. Seringkali kista ginjal tidak menimbulkan gejala, sehingga memerlukan pantauan reguler dari dokter. Dokter dapat melakukan pemeriksaan dan merencanakan tindakan penelitian lebih lanjut.

Penelitian ini fokus pada perancangan model dan klasifikasi kista menggunakan model *Deep Learning* [2]. *Deep learning* adalah subbidang dari machine learning yang menggunakan jaringan syaraf tiruan (*neural networks*) dalam memproses dan memahami data [3]. *Deep Learning* sangat efektif digunakan untuk pengenalan gambar, pemrosesan bahasa alami, dan pengenalan suara. Model deep learning dapat mengenali pola-pola terkait dengan kista ginjal sederhana atau kompleks. Salah satu jenis arsitektur dalam deep learning yang sangat sukses, terutama dalam tugas pengolahan gambar yaitu *Convolution Neural Network* (CNN) [4]. CNN adalah jenis jaringan syaraf tiruan yang digunakan dalam analisis gambar CT scan kista ginjal [5]. CNN perlu dilatih menggunakan data pelatihan dan pengujian sehingga dapat menghasilkan hasil yang akurat. Selain itu, penggunaan teknik *pre-processing* pada data yang dapat meningkatkan performa modeling dengan cara memperbanyak variasi data gambar, sehingga model klasifikasi dapat lebih efektif [6]. Dalam membuat model klasifikasi perlu memperhatikan pemahaman data, tingkat interpretabilitas model, dan penanganan *overfitting*. *Overfitting* adalah masalah yang sering terjadi dalam proses *machine learning*. *Overfitting* adalah suatu keadaan dimana model terlalu fokus terhadap data latih, sehingga model tersebut tidak dapat memproses data uji dengan baik [7]. Hal tersebut terjadi karena model terlalu fokus pada data pelatihan, serta variasi yang tidak relevan pada data pelatihan tersebut. Seharusnya model mempelajari bukan hanya mengingat pola dari data pelatihan.

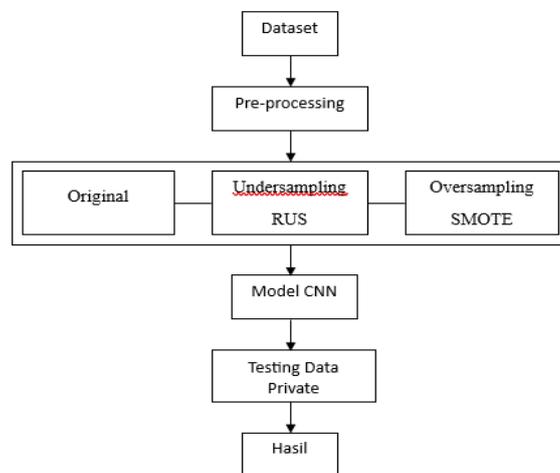
Ada beberapa cara untuk mengatasi masalah distribusi kelas, yaitu dengan penyeimbang kelas (*resampling*) [8]. *Resampling* dibagi lagi menjadi dua jenis yaitu, *undersampling* dan *oversampling*. *Undersampling* merupakan metode sampling secara acak memilih di kelas mayoritas dan menambahkannya di kelas minoritas [9]. Dan sebaliknya, *oversampling* merupakan metode sampling dengan memilih di kelas minoritas secara acak dan di duplikasi [10]. Metode *undersampling* yang digunakan untuk masalah distribusi kelas yaitu, *Random Undersampling* (RUS), *Edited Nearest Neighbors* (ENN), dan *Cluster Centroids*, dan masih banyak metode *undersampling* lainnya. Dan metode *oversampling* yang sering digunakan untuk masalah distribusi kelas yaitu, *Random Oversampling* (ROS), SMOTE (*Synthetic Minority Over-sampling Technique*), ADASYN (*Adaptive Syntetic Sampling*), MSMOTE (*Modified SMOTE*), dan masih banyak metode *undersampling* lainnya. *Random Undersampling* (RUS) merupakan metode yang sering digunakan, tujuan dari metode ini adalah menyeimbangkan kelas dengan menghapus sampel dari kelas mayoritas, sehingga jumlahnya sama dengan kelas minoritas [11]. Dan SMOTE merupakan metode yang sering digunakan, Dimana metode ini menghasilkan variasi tambahan pada data di kelas minoritas tanpa perlu menggandakan data yang sudah ada, sehingga mendukung model dalam memperoleh pemahaman yang lebih baik terhadap kelas minoritas [12]. SMOTE berhubungan dengan ruang fitur (*feature space*) dalam konteks penanganan masalah distribusi kelas yang tidak seimbang. Ruang fitur adalah ruang dimana setiap dimensi atau fitur mewakili atribut atau karakteristik tertentu dari setiap sampel dalam dataset. SMOTE bekerja dalam ruang fitur dengan cara menciptakan sampel sintetis baru untuk kelas minoritas [13].

Beberapa penelitian telah dilaksanakan oleh peneliti sebelumnya, dan memiliki fokus pada materi yang serupa dengan riset yang akan dilaksanakan. Salah satunya yaitu penelitian [14].

Penelitian tersebut membandingkan pengklasifikasian berita menggunakan data yang tidak seimbang (*imbalance*) dan pengklasifikasian menggunakan data yang telah ditingkatkan jumlahnya dengan *oversampling* menggunakan SMOTE. Penelitian tersebut menggunakan 200 data, dengan kelas minoritas berjumlah 24, dan kelas mayoritas berjumlah 176. Pendekatan klasifikasi dalam penelitian tersebut menggunakan algoritma KNN. Hasil penelitian menunjukkan bahwa penerapan *oversampling* melalui metode SMOTE berhasil meningkatkan kinerja model, dengan peningkatan akurasi rata-rata mencapai 3,36. Dari hasil penelitian tersebut, tantangan yang dihadapi adalah menangani ketidakseimbangan dataset melalui berbagai metode. Pada penelitian ini akan dilakukan pembuatan model klasifikasi kista ginjal menggunakan dataset yang tidak seimbang. Model ini akan dikembangkan melalui 3 teknik yang berbeda dan kemudian diujikan untuk mengklasifikasi data privat. Pengujian data privat dilakukan untuk mengevaluasi performa dan potensi *overfitting* pada model. Teknik yang pertama yaitu menggunakan data yang tidak seimbang untuk membuat model. Teknik yang kedua yaitu melakukan *resampling* dengan mengambil secara acak sampel dari kelas mayoritas dan menambahkannya ke dalam kelas minoritas, yang bertujuan untuk meningkatkan performa model lebih baik melalui teknik *Random Undersampling*. Dan teknik yang ketiga yaitu melakukan *oversampling* menggunakan metode SMOTE untuk mencapai distribusi data yang seimbang.

2. METODE PENELITIAN

Penelitian ini dilakukan dengan membuat model menggunakan algoritma yang sama, namun dengan penerapan *pre-processing* yang berbeda. *Pre-processing* dilakukan melalui 3 metode yang berbeda, yaitu *original*, *random undersampling*, dan SMOTE. Dataset publik yang digunakan pada penelitian ini adalah data yang bersumber dari Kaggle yang berkaitan dengan data CT scan kista ginjal. Sebelum dipakai, data tersebut diseleksi untuk diambil pada bagian spesifik ginjalnya saja. Data yang digunakan hanya pada kelas normal dan kista. Jumlah data setelah diseleksi berjumlah 3.274 untuk data normal, dan 2.248 untuk data kista. Dataset yang digunakan dalam penelitian memiliki ketidakseimbangan kelas, dimana perbedaan distribusi antar kelas mayoritas dan kelas minoritas cukup signifikan. Hal tersebut menyebabkan terjadinya *overfitting*. Untuk membandingkan tingkat *overfitting* pada masing-masing model, dilakukan pengujian menggunakan data privat, sehingga hasilnya dapat dianalisis secara komparatif. Data privat yang digunakan adalah data klinis yang diperoleh dari sampel data yang terkumpul dari Rumah Sakit Kebumen dan Rumah Sakit Sultan Agung, yang datanya dirahasiakan untuk identitas pasien. Dan data murni berupa CT scan saja. Dataset privat berfungsi untuk menguji pada model yang telah dirancang menggunakan data public. Dataset privat berjumlah 540 gambar pada kelas normal dan 602 gambar pada kelas kista. Berikut alur dari penelitian yang dilakukan.



Gambar 2 alur penelitian

Gambar diatas merupakan alur dari penelitian ini. Dataset yang digunakan merupakan data yang tidak seimbang (*imbalance data*) [15]. Kemudian dilakukan *pre-processing* data terlebih dahulu untuk mempersiapkan datanya sebelum digunakan menggunakan 3 metode yang berbeda. Setelah itu membuat model menggunakan CNN. Setelah melakukan evaluasi pada model langkah selanjutnya yaitu, menguji model menggunakan dataset privat.

Random Undersampling (RUS) merupakan metode sampling secara acak memilih sampel di kelas mayoritas sehingga sejajar dengan sampel dari kelas minoritas. Tantangan yang timbul dalam klasifikasi menggunakan machine learning adalah ketika dataset yang digunakan memiliki distribusi kelas yang tidak seimbang. Karena itu, penanganan masalah ketidakseimbangan kelas menjadi sangat krusial. Dengan melakukan teknik *resampling* RUS, dapat meningkatkan kinerja model pada kelas minoritas, mengurangi resiko *overfitting*, dan meningkatkan efisiensi pemrosesan pelatihan model [16].

Synthetic Minority Oversampling Technique (SMOTE) merupakan Teknik oversampling untuk menangani masalah ketidakseimbangan dataset, khususnya pada kelas minoritas yang intensitasnya jauh lebih rendah disbanding kelas mayoritas. Metode SMOTE beroperasi dengan menciptakan sejumlah instace buatan diantara suatu instance dalam kelas minoritas dan instance minoritas terdekatnya. Dalam praktiknya, penggunaan SMOTE dapat menghasilkan *oversampling* yang berlebihan dan mengaburkan batas antar kelas. SMOTE akan menentukan dan memilih instace yang perlu dibangkitkan selama proses *oversampling*, sehingga dapat mengatasi permasalahan *blind oversampling* yang sering terjadi pada SMOTE dan dapat mengurangi ketisakseimbangan dalam dataset [17].

3. HASIL DAN PEMBAHASAN

Penelitian ini berfokus pada tahap *pre-processing* sebelum data digunakan dalam pelatihan model. *Pre-processing* dilakukan melalui 3 teknik yang berbeda, yaitu metode *original*, *random undersampling*, dan SMOTE. Penggunaan ketiga metode tersebut bertujuan untuk mengevaluasi dan membandingkan kinerja terbaik dari masing-masing teknik, Dataset yang digunakan pada penelitian ini berasal dari Kaggle yaitu data CT scan kista ginjal [18]. Proses *pre-processing* data dengan menggunakan Teknik undersampling dengan RUS dan Teknik oversampling dengan SMOTE. *Undersampling* dan *oversampling* dilakukan untuk membuat data agar menjadi seimbang [19]. Algoritma yang digunakan pada penelitian ini yaitu CNN dengan arsitektur custom yang terdiri dari *exception layer*, *flatten layer*, *dense layer*, dan 2 *dropout layer* [20]. Berikut arsitektur yang digunakan.

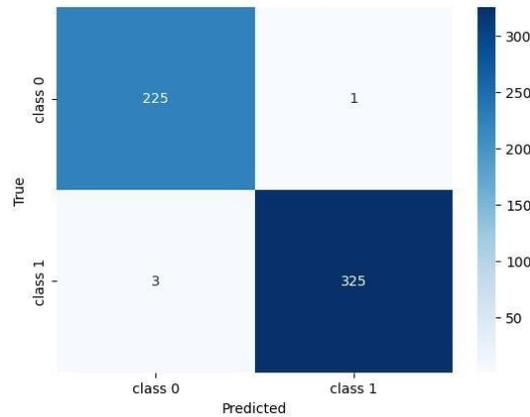
Layer (type)	Output Shape	Param #
exception (Functional)	(None, 2048)	20861480
flatten_2 (Flatten)	(None, 2048)	0
dense_5 (Dense)	(None, 256)	524544
dropout_1 (Dropout)	(None, 256)	0
dense_6 (Dense)	(None, 2)	514
=====		
Total params: 21386538 (81.58 MB)		
Trainable params: 525058 (2.00 MB)		
Non-trainable params: 20861480 (79.58 MB)		

Gambar 2 arsitektur CNN

1. Metode Original

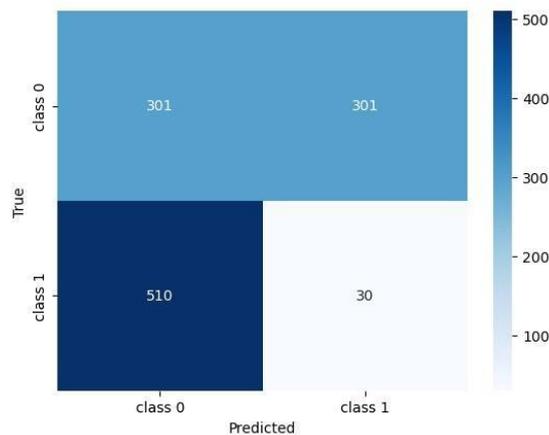
Pada pengujian model menggunakan data public menggunakan metode CNN original, dengan data latih yang masih *imbalance* yang berlangsung dengan 11 *epoch* [21], dapat diketahui

bahwa tingkat akurasinya sebesar 99% . Untuk nilai Loss sebesar 0.0217, nilai Recall sebesar 0.99, dan nilai F1_scores sebesar 0.99. Berikut merupakan *classification report*-nya



Gambar 3 *classification report* data public metode original

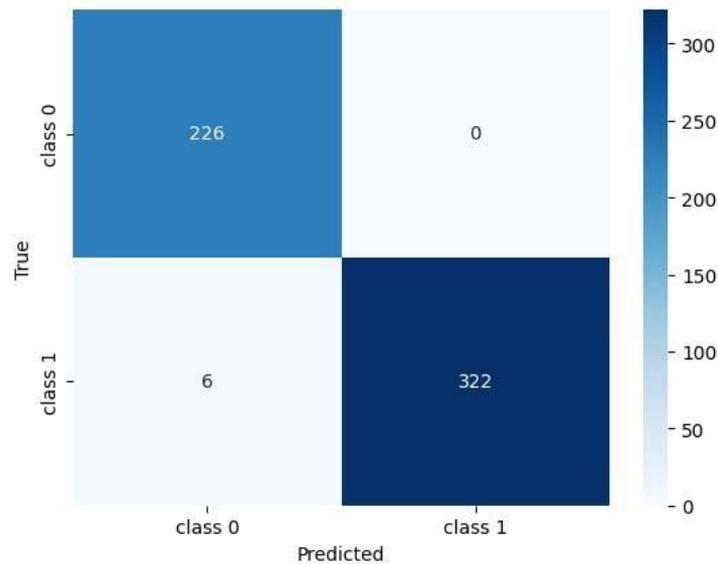
Pada pengujian data privat menggunakan metode CNN original, dapat diketahui bahwa tingkat akurasinya sebesar 28,98%. Untuk nilai Loss sebesar 2.7832, nilai Recall sebesar 0.2898, dan nilai F1_scores sebesar 0.2571. Berikut merupakan *classification report*-nya



Gambar 3 *classification report* data privat metode original

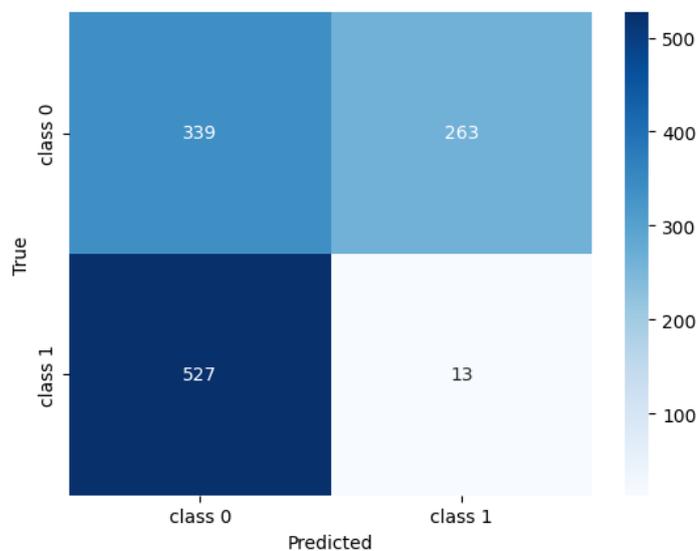
2. Metode Random Undersampling

Pada pengujian model menggunakan data public menggunakan metode Random Undersampling (RUS) dengan data latih yang masih *imbalance* yang berlangsung dengan 10 *epoch*, dapat diketahui bahwa tingkat akurasinya sebesar 99%. Untuk nilai Loss sebesar 0.0349, nilai Recall sebesar 0.99, dan nilai F1_scores sebesar 0.99. Berikut merupakan *classification report*-nya



Gambar 4 *classification report* data public metode RUS

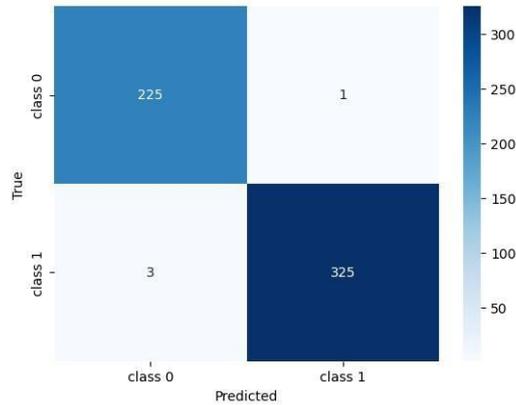
Pada pengujian data privat menggunakan metode Random Undersampling (RUS), dapat diketahui bahwa tingkat akurasinya sebesar 30,82%. Untuk nilai Loss sebesar 2.8636, nilai Recall sebesar 0.3082, dan nilai F1_scores sebesar 0.2585. Berikut merupakan *classification report*-nya



Gambar 5 *Classification report* data privat metode rus

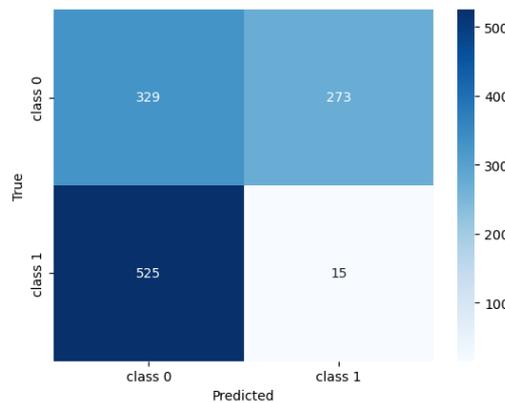
3. Metode SMOTE

Pada pengujian model menggunakan data public menggunakan metode SMOTE dengan data latih yang masih *imbalance* yang berlangsung dengan 8 *epoch*, dapat diketahui bahwa tingkat akurasinya sebesar 99%. Untuk nilai Loss sebesar 0.0293, nilai Recall sebesar 0.99, dan nilai F1_scores sebesar 0.99. Berikut merupakan *classification report*-nya



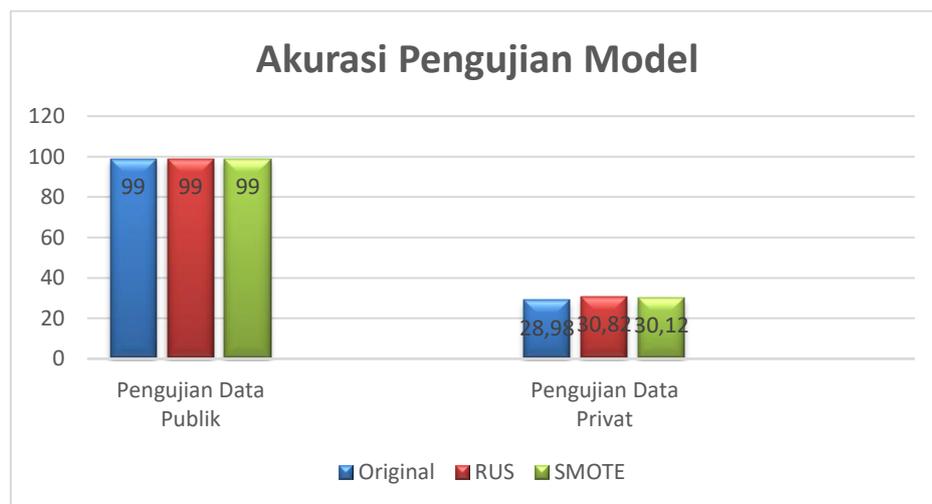
Gambar 6 Classification report data public metode SMOTE

Pada pengujian data privat dengan menggunakan SMOTE, dapat diketahui bahwa tingkat akurasinya sebesar 30,12%. Untuk nilai Loss sebesar 2.5893, nilai Recall sebesar 0.3012, dan nilai F1_scores sebesar 0.2553.



Gambar 7 Classification report data privat metode SMOTE

Setelah dilakukan pengujian menggunakan data privat, ditunjukkan hasil perbandingan akurasi sebagai berikut



Gambar 8 Grafik perbandingan akurasi pengujian

Hasil pengujian dataset yang tidak seimbang menggunakan algoritma Convolutional Neural Network dengan *undersampling* dan *oversampling*, menjelaskan bahawa metode RUS memiliki tingkat akurasi tertinggi dari dua metode lainnya.

4. KESIMPULAN DAN SARAN

Berdasarkan hasil pengujian model yang dilakukan dapat ditarik kesimpulan bahwa penggunaan teknik *undersampling* RUS memiliki tingkat akurasi tertinggi dengan nilai 30,82% untuk klasifikasi kista ginjal pada dataset tidak seimbang. Dengan tingginya akurasi pada metode RUS menunjukkan bawah model tersebut paling baik dalam mengatasi adanya *overfitting* yang terjadi pada pembuatan model dengan data *imbalance*. Karakteristik data CT scan yang memiliki variasi yang sangat banyak menyebabkan model dalam *machine learning* kesulitan untuk menemukan pola secara presisi. Oleh karena itu, diperlukan upaya untuk memecahkan masalah tersebut. Dengan demikian masih perlu dioptimalkan lagi dengan metode lain agar mendapatkan nilai akurasi yang lebih baik lagi.

DAFTAR PUSTAKA

- [1] A. Ariani, K. Kunci-Penyakit, dan G. Kronis, "Klasifikasi Penyakit Ginjal Kronis menggunakan K-Nearest Neighbor," *Prosiding Annual Research Seminar*, vol. 5, no. 1, hlm. 148–151, 2019, [Daring]. Tersedia pada: http://archive.ics.uci.edu/ml/datasets/Chronic_Kidney_Dise
- [2] Dr. A. Bashar, "SURVEY ON EVOLVING DEEP LEARNING NEURAL NETWORK ARCHITECTURES," *Journal of Artificial Intelligence and Capsule Networks*, vol. 2019, no. 2, hlm. 73–82, Des 2019, doi: 10.36548/jaicn.2019.2.003.
- [3] S. Sharma* dan M. Parmar, "Heart Diseases Prediction using Deep Learning Neural Network Model," *International Journal of Innovative Technology and Exploring Engineering*, vol. 9, no. 3, hlm. 2244–2248, Jan 2020, doi: 10.35940/ijitee.C9009.019320.
- [4] V. N. Satya dan S. Chimakurthi, "Application of Convolution Neural Network for Digital Image Processing," *Engineering International*, vol. 8, no. 2, 2020.
- [5] A. F. Suahati, A. A. Nurrahman, dan O. Rukmana, "Penggunaan Jaringan Syaraf Tiruan – Backpropagation dalam Memprediksi Jumlah Mahasiswa Baru," *Jurnal Media Teknik dan Sistem Industri*, vol. 6, no. 1, hlm. 21, Mar 2022, doi: 10.35194/jmtsi.v6i1.1589.
- [6] K. N. Abd Halim*, A. S. Mohd Jaya, dan A. F. A. Fadzil, "Data Pre-Processing Algorithm for Neural Network Binary Classification Model in Bank Tele-Marketing," *International Journal of Innovative Technology and Exploring Engineering*, vol. 9, no. 3, hlm. 272–277, Jan 2020, doi: 10.35940/ijitee.C8472.019320.
- [7] Z. Li, K. Kamnitsas, dan B. Glocker, "Analyzing Overfitting Under Class Imbalance in Neural Networks for Image Segmentation," *IEEE Trans Med Imaging*, vol. 40, no. 3, hlm. 1065–1077, Mar 2021, doi: 10.1109/TMI.2020.3046692.
- [8] S. Bagui dan K. Li, "Resampling Imbalanced Data for Network Intrusion Detection Datasets," *J Big Data*, vol. 8, no. 1, Des 2021, doi: 10.1186/s40537-020-00390-x.
- [9] J. Hoyos-Osorio, A. Alvarez-Meza, G. Daza-Santacoloma, A. Orozco-Gutierrez, dan G. Castellanos-Dominguez, "Relevant Information Undersampling to Support Imbalanced Data Classification," *Neurocomputing*, vol. 436, no. 3, hlm. 136–146, Mei 2021, doi: 10.1016/j.neucom.2021.01.033.
- [10] H. A. Ahmed, A. Hameed, dan N. Z. Bawany, "Network Intrusion Detection using Oversampling Technique and Machine Learning Algorithms," *PeerJ Comput Sci*, vol. 8, 2022, doi: 10.7717/PEERJ-CS.820.
- [11] M. C. Untoro dan M. A. N. M. Yusuf, "Evaluate of Random Undersampling Method and Majority Weighted Minority Oversampling Technique in Resolve Imabalanced Dataset," *IT Journal Research and Development*, vol. 8, no. 1, hlm. 1–13, Agu 2023, doi: 10.25299/itjrd.2023.12412.
- [12] E. Sutoyo dan M. A. Fadlurrahman, "Penerapan SMOTE untuk Mengatasi Imbalance Class dalam Klasifikasi Television Advertisement Performance Rating Menggunakan Artificial Neural Network," *Jurnal Edukasi dan Penelitian Informatika (JEPIN)*, vol. 6, no. 3, hlm. 379, Des 2020, doi: 10.26418/jp.v6i3.42896.

- [13] P. Liang, W. Li, dan J. Hu, "Oversampling the Minority Class in A Multi-Linear Feature Space for Imbalanced Data Classification," *IEEE Transactions on Electrical and Electronic Engineering*, vol. 13, no. 10, hlm. 1483–1491, Okt 2018, doi: 10.1002/tee.22715.
- [14] S. Keputusan Dirjen Penguatan Riset dan Pengembangan Ristek Dikti, A. Nikmatul Kasanah, U. Pujiyanto, T. Elektro, F. Teknik, dan U. Negeri Malang, "Penerapan Teknik SMOTE untuk Mengatasi Imbalance Class dalam Klasifikasi Objektivitas Berita Online Menggunakan Algoritma KNN," *JURNAL RESTI(Rekayasa Sistem dan Teknologi Informasi)*, vol. 1, no. 3, hlm. 196–201, 2017.
- [15] F. Thabtah, S. Hammoud, F. Kamalov, dan A. Gonsalves, "Data Imbalance in Classification: Experimental Evaluation," *Inf Sci (N Y)*, vol. 513, hlm. 429–441, Mar 2020, doi: 10.1016/j.ins.2019.11.004.
- [16] T. Wongvorachan, S. He, dan O. Bulut, "A Comparison of Undersampling, Oversampling, and SMOTE Methods for Dealing with Imbalanced Classification in Educational Data Mining," *Information (Switzerland)*, vol. 14, no. 1, Jan 2023, doi: 10.3390/info14010054.
- [17] R. Wardoyo, I. M. A. Wirawan, dan I. G. A. Pradipta, "Oversampling Approach Using Radius-SMOTE for Imbalance Electroencephalography Datasets," *Emerging Science Journal*, vol. 6, no. 2, hlm. 382–398, Apr 2022, doi: 10.28991/ESJ-2022-06-02-013.
- [18] H. Mukherjee, S. Ghosh, A. Dhar, S. M. Obaidullah, K. C. Santosh, dan K. Roy, "Deep Neural Network to Detect COVID-19: One Architecture for both CT Scans and Chest X-rays," *Applied Intelligence*, vol. 51, no. 5, hlm. 2777–2789, Mei 2021, doi: 10.1007/s10489-020-01943-6.
- [19] J. Agili Lopo dan K. Dwi Hartomo, "Evaluating Sampling Techniques for Healthcare Insurance Fraud Detection in Imbalanced Dataset," *Jurnal Ilmiah Teknik Elektro Komputer dan Informatika (JITEKI)*, vol. 9, no. 2, hlm. 223–238, 2023, doi: 10.26555/jiteki.v9i2.25929.
- [20] L. Alzubaidi *dkk.*, "Review of Deep Learning: concepts, CNN architectures, challenges, applications, future directions," *J Big Data*, vol. 8, no. 1, Des 2021, doi: 10.1186/s40537-021-00444-8.
- [21] R. R. Putra, I. G. T. Isa, A. B. J. Malyan, E. Laila, dan A. T. Wardhana, "Level Optimum Hyperparameter Tuning Epoch dalam Klasifikasi Citra Bencana Kebakaran," *JTERA (Jurnal Teknologi Rekayasa)*, vol. 7, no. 2, hlm. 209, Des 2022, doi: 10.31544/jtera.v7.i2.2022.209-216.