

ANALISIS PERBANDINGAN PERFORMA METODE ENSEMBLE DALAM MENANGANI *IMBALANCED MULTI-CLASS CLASSIFICATION*

Qorry Meidianingsih¹, Devi Eka Wardani Meganingtyas²

¹Program Studi Pendidikan Matematika, Fakultas MIPA, Universitas Negeri Jakarta

²Program Studi Matematika, Fakultas MIPA, Universitas Negeri Jakarta

e-mail: ¹qorrymeidianingsih@unj.ac.id, ²deviekawm@unj.ac.id

Abstrak

Penelitian ini fokus pada membandingkan kinerja beberapa metode *ensemble* dalam mengatasi *imbalanced multi-class classification* dimana metode dekomposisi *one-versus-one* (OVO) diterapkan sehingga metode klasifikasi *Support Vector Machine* yang standar dapat digunakan. Data penelitian merupakan hasil bangkitan *software R* yang dirancang berdasarkan level persentase kelas minoritas, yaitu menjadi kategori *extreme*, *moderate*, dan *mild*. Selain itu, dirancang pula kombinasi jumlah kelas mayoritas dan minoritas yang mungkin terjadi sehingga terdapat sembilan jenis data simulasi. Hasil penelitian menunjukkan bahwa secara umum rata-rata ketepatan klasifikasi paling rendah diperoleh ketika data simulasi bersifat *moderate* dengan sebaran gugus data terbagi menjadi 2 kelas mayoritas dan 1 kelas minoritas. Metode *safe-level SMOTEBagging* memberikan performa yang paling baik bagi semua jenis data simulasi, terutama ketika gugus data bersifat ekstrim, yaitu ditunjukkan dengan nilai rata-rata akurasi yang diperoleh sebesar 98.60 persen. Kinerja metode klasifikasi SVM cukup baik dimana nilai rata-rata tingkat akurasi setiap kelas berkisar antara 67.80-98.60 persen.

Kata kunci: *imbalanced multi-class, ensemble method, bagging, underbagging, SMOTEBagging, safe-level SMOTE, support vector machine*

Abstract

This study focused on comparing the performance of several ensemble methods in handling imbalanced multi-class classification where the one-versus-one (OVO) decomposition method is applied so that the standard Support Vector Machine classification method can be used. The data were generated by R software which is designed based on the percentage level of the minority class, namely into "extreme", "moderate", and "mild" categories. In addition, a combination of the number of majority and minority classes that may occur is designed so that there are nine types of simulation data. The results showed that in general the lowest average classification accuracy was obtained when the simulation data was moderate with the distribution of the data set divided into 2 majority classes and 1 minority class. The safe-level SMOTEBagging method provides the best performance for all types of simulation data, especially when the data set is extreme, which is indicated by the average accuracy obtained of 98.60 percent. The performance of the SVM classification method is quite good where the average value of the accuracy level of each class ranges from 67.80-98.60 percent.

Keywords: *imbalanced multi-class, ensemble method, bagging, underbagging, SMOTEBagging, safe-level SMOTE, support vector machine*

PENDAHULUAN

Penelitian yang melibatkan data besar (*big data*) menjadi kajian yang banyak dipelajari oleh komunitas *data mining* dan *machine learning*. Skenario masalah yang ditemukan pun lebih beragam sehingga dapat memberikan berbagai pilihan topik, dimana salah satu yang mendapat perhatian yaitu mengenai kelas tidak seimbang. Berbagai penelitian telah dilakukan untuk menangani permasalahan klasifikasi ketika kelas tidak seimbang, namun banyak literatur yang lebih fokus pada kelas bersifat biner (memiliki dua kelas).

Permasalahan data dengan ketidakseimbangan pada *multi-class* mulai mendapatkan perhatian dari komunitas peneliti dalam beberapa tahun terakhir (Lango, 2019). Literatur mengenai *pattern recognition* telah banyak membahas teknik klasifikasi pola pada *multi-class*, namun sebagian besar teknik tersebut menerapkannya pada kondisi data yang seimbang, seperti klasifikasi dokumen tertulis dan pengenalan suara, meskipun dalam banyak penerapan di bidang lain data yang ditemukan lebih sering memiliki kelas yang tidak seimbang (Ghanem *et. al.*, 2010). Dalam menangani permasalahan ketidakseimbangan *multi-class*, kita akan dihadapkan pada gugus data dengan konfigurasi yang berbeda, seperti kemungkinan untuk memiliki tidak hanya satu kelas mayoritas tetapi beberapa dan sebaliknya dimana satu kelas mayoritas dan beberapa kelas minoritas (Esteves, 2020). Beberapa metode standar pun tidak dapat diterapkan secara langsung pada kasus ketidakseimbangan *multi-class*. Hal ini lah yang membuat permasalahan klasifikasi pada kasus *imbalanced multi-class* menjadi lebih rumit. Metode yang digunakan harus mencoba untuk menangkap dan menggali lebih jauh hubungan antara beberapa kelas yang tidak seimbang serta siap untuk bekerja dengan ketidakseimbangan yang lebih ekstrim karena mereka lebih mungkin terjadi dalam gugus data *multi-class* (Lango, 2019).

Dalam mengatasi permasalahan klasifikasi *multi-class*, metode dekomposisi merupakan salah satu yang populer, sedangkan metode *ensemble* dapat digunakan untuk menangani permasalahan ketidakseimbangan kelasnya. Metode dekomposisi diterapkan untuk membagi gugus data *multi-class* menjadi multipel sub-kelas biner sehingga nantinya akan menghasilkan pengklasifikasi biner sebanyak sub-kelas. Metode *ensemble* yang digunakan untuk menyeimbangkan jumlah amatan kelas pun beragam, di antaranya *boosting* dan *bagging*. Penyeimbangan jumlah amatan antara kelas mayoritas dan minoritas memungkinkan metode klasifikasi standar dapat diterapkan, salah satunya yaitu *Support Vector Machine*. Penelitian ini fokus kepada membandingkan kinerja beberapa metode *ensemble*, yaitu *underbagging*, *SMOTEBagging*, dan *safe-level SMOTEBagging*, dalam mengatasi *imbalanced multi-class classification* menggunakan metode dekomposisi *one-versus-one* (OVO). Dengan demikian hasil penelitian ini diharapkan dapat memberikan alternatif lain dalam mengatasi kasus klasifikasi untuk gugus data *multi-class* yang tidak seimbang.

METODOLOGI

Tinjauan Referensi

Pendekatan yang diperkenalkan untuk mengatasi permasalahan data dengan kelas tidak seimbang hampir sebagian besar hanya dirancang untuk skenario kelas biner. Beberapa metode tidak dapat diterapkan secara langsung pada kasus ketidakseimbangan *multi-class*. Solusi yang ditawarkan dalam mengatasi ketidakseimbangan *multi-class* cukup beragam, namun sebagian besar literatur mengarahkan pada metode dekomposisi kelas atau mengkonversi masalah *multi-class* menjadi sekumpulan sub-kelas biner. (Wang dan Yao, 2012). Metode dekomposisi tersebut pada awalnya digunakan pada penerapan klasifikasi

multi-class yang seimbang, namun Esteves (2020) memberikan penguatan bahwa metode tersebut dapat dipelajari oleh pengklasifikasi biner sekalipun kondisi datanya tidak seimbang.

One-versus-all (OVA) dan *One-versus-one* (OVO) merupakan dua pendekatan yang membagi masalah untuk memungkinkan hasil yang diperoleh menjadi lebih baik. Kedua metode tersebut sangat dikenal ketika melakukan dekomposisi kelas. OVA pertama kali didiskusikan sebagai sebuah teknik oleh Clark dan Boswell pada tahun 1991 (dalam Esteves, 2020). Ide dari metode OVA yaitu memberikan label pada salah satu kelas sebagai positif dan kelas lainnya sebagai negatif lalu menerapkan metode klasifikasi yang sama pada semua kelas dan membuat model klasifikasi berdasarkan data latih. Hasil dari metode tersebut adalah model klasifikasi multipel biner yang dapat dibandingkan hingga diperoleh yang terbaik. Metode *one-versus-one* (OVO) diperkenalkan oleh Knerr *et al.* pada tahun 1990 (dalam Azis *et al.*, 2017). Pada metode OVO, metode klasifikasi biner dibangun oleh setiap pasangan kelas. Pendekatan sederhana untuk menggabungkan semua hasil dari metode klasifikasi biner pada OVO yaitu menggunakan *majority voting* dimana contoh uji akan diklasifikasikan ke dalam kelas yang memiliki *vote* tertinggi (Ghanem *et. al.*, 2010).

Secara umum metode OVO lebih disukai untuk data dengan kelas yang tidak seimbang karena masalah biner yang dibangun oleh OVA bahkan lebih sangat tidak seimbang daripada masalah yang sebenarnya. Di sisi lain, metode OVO akan memakan banyak waktu dan biaya ketika jumlah kelas yang dimiliki semakin banyak karena akan menghasilkan pengklasifikasi sub-kelas yang sangat banyak dan memungkinkan untuk memberikan masalah yang rumit dalam pengerjaannya (Lango, 2019). Meskipun demikian, penelitian yang dilakukan oleh Rout dan Mishra (2018) memberikan hasil yang positif mengenai aplikasi metode OVO.

Penelitian tersebut berupa eksperimen untuk menganalisis permasalahan klasifikasi pada imbalanced *multi-class*. Metode OVO diterapkan pada gugus data penelitian sehingga dihasilkan sekumpulan kelas biner yang tidak seimbang. Beberapa metode ensemble berbasis boosting selanjutnya digunakan untuk menghasilkan gugus sub-kelas yang seimbang sehingga metode klasifikasi biner dapat diterapkan. Penggunaan metode OVO dipilih pada penelitian tersebut dengan merujuk pada penelitian yang dilakukan oleh Saez *et al.* (2014) yang memberikan hasil bahwa metode OVO menunjukkan performa yang lebih baik dan pengklasifikasi yang lebih robust ketika berhadapan dengan data yang memiliki noise.

Dalam menangani permasalahan ketidakseimbangan kelas, pendekatan solusi yang telah banyak dikenal yaitu pada level data preprocessing dan modifikasi algoritma metode klasifikasi standar. Data preprocessing merupakan tahap mengubah sebaran data dari semua kelas menjadi seimbang mungkin. Gugus data yang telah melewati tahap ini selanjutnya dapat diterapkan suatu pengklasifikasi tunggal dan diukur kinerjanya. Salah satu metode yang menarik perhatian adalah metode ensemble, yaitu menggabungkan banyak pengklasifikasi (classifier) tunggal yang kemudian hasil prediksi dari masing-masing pengklasifikasi digabungkan dengan proses voting. Salah satu algoritma metode ensemble yang dapat digunakan dalam skenario *multi-class* adalah bagging. Apabila dibandingkan dengan pengklasifikasi tunggal, hasil prediksi bagging hampir selalu lebih akurat (Zhou, 2012).

Tanha *et al.* (2020) mengevaluasi berbagai metode berbasis algoritma boosting pada dua tipe gugus data *multi-class* yang tidak seimbang, yaitu konvensional dan data besar. Metode OVO diterapkan untuk membagi gugus data *multi-class* menjadi multipel sub-kelas biner. Hasil penelitian menunjukkan bahwa tidak ada algoritma boosting yang

menunjukkan performa baik pada gugus data besar yang memiliki tingkat ketidakseimbangan kelasnya tinggi. Nilai G-mean yang sangat kecil menunjukkan bahwa metode boosting tidak dapat mempelajari beberapa kelas pada gugus data. Oleh karena itu, algoritma boosting tidak cocok digunakan pada data besar dengan rasio ketidakseimbangan kelas yang lebih tinggi. Meskipun begitu, pada penelitian tersebut ditemukan bahwa teknik oversampling cukup efektif untuk gugus data multi-class yang tidak seimbang.

Kajian beberapa teori dan hasil penelitian sebelumnya yang terkait dengan penelitian ini memberikan gambaran bahwa algoritma *bagging* sebagai salah satu bagian dari metode *ensemble* belum banyak dilibatkan dalam topik penelitian *imbalanced multi-class classification*. Penggunaan metode dekomposisi *one-versus-one* dan penerapan *support vector machine* sebagai metode klasifikasi diharapkan mampu memberikan hasil prediksi yang lebih baik. Hal ini didukung dengan alasan bahwa *Support Vector Machine* merupakan salah satu metode yang kini banyak mendapat perhatian sebagai *state of the art* dalam klasifikasi *pattern recognition* (Azis *et al.*, 2017).

UnderBagging

Barandela *et al.* (2003) memperkenalkan metode *UnderBagging* pada tahun 2003. Metode ini merupakan gabungan antara teknik pengambilan contoh *undersampling* dan teknik *ensemble bagging*. Ide dari metode ini yaitu membuat beberapa data latih sebanyak k kali dimana seluruh amatannya berasal dari kelas minoritas dan menarik secara acak amatan kelas mayoritas dengan jumlah yang sama atau dengan teknik tanpa pengembalian (Blaszczynski *et al.*, 2013). Selanjutnya metode klasifikasi diterapkan pada setiap data latih tersebut sehingga diperoleh k buah klasifikasi sehingga hasil prediksi gabungannya ditentukan berdasarkan *majority vote*.

SMOTEBagging

Synthetic Minority Oversampling Technique (SMOTE) merupakan salah satu teknik *oversampling* yang diperkenalkan oleh Chawla *et al.* pada tahun 2002. Oleh karena itu, *SMOTEBagging* merupakan kombinasi antara metode SMOTE dengan algoritma *bagging* yang diperkenalkan oleh Breiman (1996). Ide dari *SMOTEBagging* adalah menerapkan SMOTE sebelum pemodelan pada setiap gugus data yang diperoleh melalui proses *bootstrap* agar kelas menjadi lebih seimbang. Tujuan dari metode ini adalah menciptakan model yang *powerful* dalam mengklasifikasi data yang tidak seimbang tanpa mengorbankan akurasi secara keseluruhan (Hanifah, 2015).

Prosedur SMOTE menurut Chawla *et al.* (2002) adalah sebagai berikut:

1. Tentukan k tetangga terdekat untuk setiap amatan kelas minoritas.
2. Pilih 1 dari k tetangga terdekat secara acak.
3. Tentukan nilai selisih antara amatan kelas minoritas dan tetangga terdekat yang terpilih.
4. Kalikan hasil pada tahap 3 dengan bilangan acak antara 0 dan 1.
5. Tambahkan hasil di poin 4 dengan amatan kelas minoritas yang awal.
6. Hasil tahap 5 merupakan data sintesis yang dibangkitkan.

Safe-level SMOTEBagging

Metode ini sebenarnya mengadaptasi algoritma yang diterapkan pada *SMOTEBagging*. Perbedaan antara metode ini dengan *SMOTEBagging* terletak pada cara membangkitkan data sintesisnya dimana dilakukan berdasarkan pada kriteria wilayah aman yang diperkenalkan oleh Bunkhumpornpat *et al.* (2009).

Ukuran Kinerja Metode Klasifikasi

Dalam mengevaluasi kinerja metode klasifikasi pada kasus *multi-class*,

prosedurnya dapat mengikuti pada kasus kelas biner. Lapalme dan Sokolova (2009) menjabarkan lebih rinci penerapan perhitungan akurasi berdasarkan *confusion matrix* ketika klasifikasi diterapkan pada *multi-class*.

$$\text{Average Accuracy} = \frac{\sum_{i=1}^l \frac{TP_i + TN_i}{TP_i + FP_i + FN_i + TN_i}}{l}$$

Keterangan:

TP_i : *True positive* atau banyaknya amatan kelas positif yang diklasifikasikan dengan tepat pada kelas ke- i

TN_i : *True negative* atau banyaknya amatan kelas negatif yang diklasifikasikan dengan tepat pada kelas ke- i

FP_i : *False positive* atau banyaknya amatan kelas negatif dan diklasifikasikan ke dalam kelas positif pada kelas ke- i

FN_i : *False negative* atau banyaknya amatan kelas positif dan

diklasifikasikan ke dalam kelas negatif pada kelas ke- i

l : jumlah kelas

Metode Analisis


Penelitian ini menggunakan data simulasi, yaitu data hasil *generate* melalui *software R*. Variabel penelitian terdiri dari variabel prediktor X_1 dan X_2 yang bersifat numerik, sedangkan peubah responnya terdiri dari tiga kelas, yaitu 1, 2, dan 3. Terdapat beberapa skema data simulasi yang ditentukan berdasarkan tingkat persentase kelas minoritas serta banyaknya kelas minoritas pada satu gugus data simulasi. Hal tersebut merupakan implikasi dari kondisi *multi-class* yang memungkinkan dalam satu gugus data terdapat lebih dari satu kelas minoritas atau kelas mayoritas seperti yang disajikan pada Tabel 1. Dengan demikian, data simulasi yang dibangkitkan diharapkan dapat menangkap kemungkinan-kemungkinan tersebut.

Tabel 1. Skema Data Simulasi

Jenis Data	Persentase (%)			Keterangan
	Kelas 1	Kelas 2	Kelas 3	
<i>Extreme</i>	75	24	1	1 mayoritas, 1 minoritas
	50	49	1	2 mayoritas, 1 minoritas
	98	1	1	1 mayoritas, 2 minoritas
<i>Moderate</i>	75	20	5	1 mayoritas, 1 minoritas
	48	47	5	2 mayoritas, 1 minoritas
	90	5	5	1 mayoritas, 2 minoritas
<i>Mild</i>	65	25	10	1 mayoritas, 1 minoritas
	45	45	10	2 mayoritas, 1 minoritas
	80	10	10	1 mayoritas, 2 minoritas

Secara umum, terdapat 3 jenis data simulasi, yaitu *extreme*, *moderate*, dan *mild*. Kelas 1 ditetapkan sebagai kelas mayoritas, sedangkan kelas 3 ditentukan sebagai kelas minoritas. Kelas 2 ditentukan sebagai kelas minoritas ke-2 ketika dalam satu gugus data terdapat dua kelas minoritas, atau kelas mayoritas ke-2 jika hanya terdapat 1 kelas minoritas dalam gugus data. Bentuk sebaran ketiga kelas

dirancang agar saling beririsan. Sebaran tersebut dipilih untuk melihat performa metode penyeimbang kelas, seperti SMOTE dan *safe-level* SMOTE. Dengan demikian, sebaran data yang beririsan akan menentukan apakah data sintesis akan memberikan hasil klasifikasi yang baik atau sebaliknya.



Gambar 1. Contoh *Scatter Plot* Data Simulasi *Extreme* (1 mayoritas, 2 minoritas)

Tahapan analisis secara umum adalah sebagai berikut.

1. Membangkitkan data simulasi menggunakan *software R* dengan tahapan sebagai berikut.
 - 1) Membangkitkan 10.000 amatan populasi menggunakan bilangan acak normal multivariat.
 - 2) Membagi seluruh amatan populasi untuk kelas 1, kelas 2, dan kelas 3 sesuai dengan proporsi yang telah ditentukan pada Tabel 1.
 - 3) Tahap 1 dan 2 dilakukan untuk jenis data *extreme*, *moderate*, dan *mild* sehingga diperoleh 9 gugus data simulasi.
2. Membagi setiap gugus data simulasi menjadi data latih (80%) dan data uji (20%). Pemilihan data latih dan uji dilakukan berdasarkan teknik pengambilan sampel acak sederhana. Total terdapat sembilan buah gugus data simulasi.
3. Membentuk sub-kelas atau subset biner pada setiap data latih.
4. Menerapkan metode *Undersampling*, *SMOTE*, dan *safe-level SMOTE* pada masing-masing sub-kelas untuk membuat jumlah amatan di semua kelas menjadi seimbang.
5. Menerapkan metode klasifikasi *Support Vector Machine* dengan fungsi kernel radial basis pada setiap sub-kelas.
6. Menentukan hasil prediksi berdasarkan model *SVM* yang telah terbentuk menggunakan data uji.

7. Ulangi tahap 4-6 sebanyak 50 ($k=50$) kali dengan pemilihan sampel berulang menggunakan teknik *bootstrap*.
8. Lakukan *majority voting* berdasarkan hasil yang diperoleh pada tahap 7. Tahap ini disebut juga sebagai *bagging* atau *bootstrap aggregating*.
9. Hasil prediksi berdasarkan *bagging* pada setiap sub-kelas selanjutnya digabung dan dicari kembali nilai *majority voting*-nya. Hasil tersebutlah yang dijadikan sebagai hasil prediksi akhir.

HASIL DAN PEMBAHASAN

Penerapan Metode Dekomposisi OVO

Metode dekomposisi *one-versus-one* (OVO) diterapkan pada data latih yang telah terpilih secara acak. Andaikan kelas biner yang baru dinotasikan dengan kelas 1 dan 0, maka proses dekomposisi 3 kelas awal (kelas 1, 2, 3) akan menghasilkan 3 kelas biner seperti yang disajikan pada Tabel 2 berikut ini.

Tabel 2. Dekomposisi Kelas

Kelas Biner (Subset) ke-	Kelas 1	Kelas 0
1 (Subset A)	1	2
2 (Subset B)	1	3
3 (Subset C)	2	3

Gambaran penentuan hasil prediksi berdasarkan proses *bagging* dan dekomposisi dapat dilihat pada tabel 3 dan 4. Keseluruhan proses tersebut diterapkan pada seluruh jenis data simulasi.

Tabel 3 Hasil Prediksi Kelas berdasarkan Metode *Ensemble*

Amatan Data Uji ke-	<i>Undersampling</i>				SMOTE				<i>Safe-level SMOTE</i>			
	<i>Bootstrap ke-</i>											
	1	2	...	50	1	2	...	50	1	2	...	50
1												
2												
3												
⋮												
2000												

Tabel 4 Hasil Prediksi Kelas berdasarkan Metode Dekomposisi

Amatan Data Uji ke-	<i>UnderBagging</i>			Hasil Prediksi Kelas (<i>UnderBagging</i>)	<i>SMOTEBagging</i>			Hasil Prediksi Kelas (<i>SMOTEBagging</i>)	<i>Safe-level SMOTEBagging</i>			Hasil Prediksi Kelas (<i>Safe-level SMOTEBagging</i>)
	1 vs 2	1 vs 3	2 vs 3		1 vs 2	1 vs 3	2 vs 3		1 vs 2	1 vs 3	2 vs 3	
	1											
2												
3												
⋮												
2000												

Performa Metode Klasifikasi

Performa metode klasifikasi SVM dapat dilihat berdasarkan hasil prediksi model berdasarkan data uji. Tabel 5, 6, dan 7 menunjukkan persentase rata-rata ketepatan setiap kelas dalam melakukan prediksi atau klasifikasi. Notasi UB ditujukan untuk *underbagging*, SMB untuk *SMOTEBagging*, dan SFB untuk *safe-level SMOTEBagging*.

Tabel 5. Persentase (%) rata-rata ketepatan klasifikasi setiap kelas berdasarkan tipe data *extreme*

Skema Data Simulasi	UB	SMB	SFB
1 kelas mayoritas, 1 kelas minoritas	73.30	75.77	83.33
2 kelas mayoritas, 1 kelas minoritas	68.73	71.70	75.33
1 kelas mayoritas, 2 kelas minoritas	76.97	81.23	98.60

Tabel 6. Persentase (%) rata-rata ketepatan klasifikasi setiap kelas berdasarkan tipe data *moderate*

Skema Data Simulasi	UB	SMB	SFB
---------------------	----	-----	-----

1 kelas mayoritas, 1 kelas minoritas	73.63	76.10	83.20
2 kelas mayoritas, 1 kelas minoritas	67.97	67.80	74.37
1 kelas mayoritas, 2 kelas minoritas	78.83	79.03	93.67

Tabel 7. Persentase (%) rata-rata ketepatan klasifikasi setiap kelas berdasarkan tipe data *mild*

Skema Data Simulasi	UB	SMB	SFB
1 kelas mayoritas, 1 kelas minoritas	73.80	77.13	77.50
2 kelas mayoritas, 1 kelas minoritas	70.87	71.53	74.87
1 kelas mayoritas, 2 kelas minoritas	76.30	76.60	88.37

Secara umum, rata-rata ketepatan klasifikasi paling rendah diperoleh ketika data simulasinya bersifat *moderate* dengan sebaran gugus data terbagi menjadi 2 kelas mayoritas dan 1 kelas minoritas (tipe ke-2). Sekalipun persentase kelas minoritas telah ditingkatkan (bersifat *moderate*), namun penerapan metode *Undersampling*, *SMOTE*, dan *safe-level SMOTE* dalam

menangani permasalahan kelas tidak seimbang terlihat kurang berhasil dalam memberikan model klasifikasi yang baik pada tipe data tersebut. Hal tersebut berbeda ketika tipe data yang digunakan bersifat *extreme*. Metode *SMOTEBagging* dan *safe-level SMOTEBagging* mampu menghasilkan rata-rata tingkat akurasi yang tinggi dimana nilainya secara berturut-turut sebesar 81.23 persen dan 98.60 persen. Berdasarkan hasil tersebut, terlihat bahwa metode *safe-level SMOTEBagging* memberikan performa yang sangat baik ketika gugus data bersifat ekstrim. Kinerja yang konsisten juga bisa dilihat pada jenis data simulasi lainnya. Rata-rata tingkat akurasi setiap kelas ketika metode *safe-level SMOTEBagging* diterapkan menunjukkan nilai yang cukup tinggi. Ide untuk membangkitkan data sintesis pada wilayah yang *safe* masih memberikan hasil yang positif dibandingkan dengan metode *SMOTEBagging* dan *UnderBagging*.

KESIMPULAN

Berdasarkan hasil penelitian, metode *safe-level SMOTEBagging* memberikan performa yang paling baik bagi semua jenis data simulasi, terutama ketika gugus data bersifat ekstrim, yaitu ditunjukkan dengan nilai rata-rata akurasi yang diperoleh sebesar 98.60 persen. Performa metode klasifikasi SVM dapat dilihat dari nilai rata-rata tingkat akurasi setiap kelas yang masih cukup tinggi (berkisar antara 67.80-98.60 persen). Dengan kata lain, strategi dekomposisi *one-versuse-one* cukup berhasil memecahkan masalah *multi-class* sehingga SVM standar dapat langsung diterapkan.

DAFTAR PUSTAKA

Azis, A. I. S., Suhartono, V., & Himawan, H. (2017). Model Multi-class SVM Menggunakan Strategi 1V1 untuk Klasifikasi Wall-Following Robot Navigation Data. *Jurnal Teknologi Informasi*, 13(2).

Barandela J., Sanchez, J.S., Garcia, V., & Rangel, E. (2003). Strategies for

Learning in Class Imbalance Problems. *The Journal of the Pattern Recognition Society*, 36, 849-851.

Blaszczynski, J., Stefanowski, J., & Idkowiak, L. (2013). Extending bagging for imbalanced data. *Proc. of the 8th CORES 2013, Springer Series on Advances in Intelligent Systems and Computing*, 226, 269-278.

Breiman, L. (1996). Bagging Predictors. *Machine Learning*, 24, 123-140. <https://doi.org/10.1023/A:1018054314350>.

Bunghumpornpat C., Sinapiromsaran K., Lursinsap C. (2009) Safe-Level-SMOTE: Safe-Level-Synthetic Minority Over-Sampling TEchnique for Handling the Class Imbalanced Problem. In: Theeramunkong T., Kijirikul B., Cercone N., Ho TB. (eds) *Advances in Knowledge Discovery and Data Mining. PAKDD 2009. Lecture Notes in Computer Science*, 5476, 475-482. https://doi.org/10.1007/978-3-642-01307-2_43.

Chawla, N. V., Bowyer, K. W., Hall, L.O., & Kegelmeyer, W. P. (2002). SMOTE: Synthetic Minority Over-sampling Technique. *Journal of Artificial Intelligence Research*, 16, 321-357. <https://doi.org/10.1613/jair.953>.

Esteves, V. M. S. (2020). Techniques to deal with imbalanced data in multi-class problems: A review of existing methods. *Faculdade de Engenharia da Universidade do Porto*.

Ghanem, A. S., Venkatesh, S., & West, G. (2010). Multi-class pattern classification in imbalanced data. *Proceedings: 20th International Conference on Pattern Recognition, IEEE, Los Alamitos, Calif.*, 2881-2884. <https://doi.org/10.1109/ICPR.2010.706>.

Hanifah FS. 2015. Penerapan algoritme *SMOTEBagging* dalam penyusunan pohon keputusan dan regresi logistik untuk kajian kredit macet [tesis]. Bogor (ID): Institut Pertanian Bogor.

Lango, M. (2019). Tackling the Problem of Class Imbalance in Multi-class

- Sentiment Classification: An Experimental Study. *Scienco*, 44(2). <https://doi.org/10.2478/fcds-2019-0009>.
- Rout, N., Kuhoo, & Mishra, D. (2018). Analysing the Multi-class Imbalanced Datasets using Boosting Methods and Relevant Information. *International Journal of Pure and Applied Mathematics*, 120(6), 6171-6191.
- Saez, J. A., Galar M., Luengo, J., & Herrera, F. (2014). Analysing the presence of noise in multi-class problems: alleviating its influence with the One-vs-One decomposition. *Knowledge and Information Systems*, 38(1), 179-206. <https://doi.org/10.1007/s10115-012-0570-1>.
- Tanha, J., Abdi, Y., Samadi, N., Razzaghi, N., & Asadpour, M. (2020). Boosting methods for multi-class imbalanced data classification: an experimental review. *Journal of Big Data*, 7(70). <https://doi.org/10.1186/s40537-020-00349-y>.
- Wang, S. & Yao, X. (2012). Multi-class Imbalance Problems: Analysis and Potential Solutions. *IEEE Transactions on Systems, Man, and Cybernetics - Part B: Cybernetics*, 42(4). <https://doi.org/10.1109/TSMCB.2012.2187280>.
- Zhou, Z. (2012). *Ensemble Methods: Foundations and Algorithms*. CRC Press