

Study of Bagging Application in the Safe-Level Smote Method in Handling Unbalanced Classification*

Kajian Penerapan Bagging pada Metode Safe-Level Smote dalam Penanganan Klasifikasi Kelas Tidak Seimbang

Qorry Meidianingsih^{1‡} and Debby Agustine²

¹Study Program of Mathematics Education, State University of Jakarta (UNJ), Indonesia

² Study Program of Mathematics, State University of Jakarta (UNJ), Indonesia

[‡]corresponding author: qorrymeidianingsih@unj.ac.id

Copyright © 2021 Qorry Meidianingsih and Debby Agustine. This is an open-access article distributed under the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

Abstract

The problems of imbalanced class classification have been found in many real applications. It has potential to make the minority class instances tend to be classified into the majority class. This study examined the performance of bagging method's application in safe-level SMOTE based on Support Vector Machine classifier. The data used consisted of three types based on the proportion of observations in the majority and minority classes. Each type of data has three variables, two independent variables and one variable dependent. The observations of independent variables were generated based on multivariate normal distribution, while dependent variables are binary. The results showed that the classifier has a high accuracy and sensitivity for all types of data for both in the imbalanced class and the balanced class (obtained by safe-level SMOTE and safe-level SMOTEBagging). Nevertheless, specificity was the main measure in assessing the performance of the classifier because it provides accuracy in classifying the minority class observations. The specificity increased when the number of observations between the two classes were approximately balance due to the implementation of safe-level SMOTE. The best performance of the Support Vector Machine in predicting minority class observations was achieved when bagging were applied in safe-level SMOTE. The specificity rate for all types of data were 77.93 percent, 78.46 percent, and 85.69 percent, respectively.

Keywords: bagging, imbalanced class, smote, safe-level smote, support vector machine.

* Received: Nov 2020; Reviewed: Jan 2021; Published: Mar 2021

1. Pendahuluan

Permasalahan klasifikasi menjadi kajian yang dipelajari oleh komunitas data mining dan *machine learning* pada berbagai bidang. Klasifikasi merupakan topik yang beragam dan algoritme yang digunakan sangat bergantung kepada domain data dan skenario masalah yang dihadapi. Oleh karena itu, masalah yang ditemui mungkin lebih beragam (Aggarwa, 2015). Salah satu permasalahan yang terjadi dalam klasifikasi dan kini banyak dipelajari oleh peneliti yaitu terkait dengan kelas tidak seimbang (Japkowicz, 2000). Beberapa penelitian telah dilakukan dalam mengembangkan teknik untuk kasus data dengan kelas tidak seimbang. (He & Garcia, 2009) serta Galar *et al.* (2011) menjelaskan beberapa metode yang dapat digunakan untuk mengatasi masalah data tidak seimbang. (Hanifah *et al.*, 2015) memprediksi calon debitur kredit tanpa agunan yang berpotensi gagal dalam memenuhi kewajibannya kepada bank (kredit macet). Hasil penelitian menunjukkan bahwa jika metode klasifikasi regresi logistik diterapkan pada data tersebut, maka tingkat akurasi yang diperoleh sebesar 86 persen dengan tingkat kepekaannya 0 persen atau seluruh nasabah kredit macet diklasifikasikan ke dalam status kredit lancar. Metode klasifikasi standar tidak dapat menghasilkan keputusan akhir yang tepat ketika kondisi kelas tidak seimbang. Hal ini disebabkan salah satu kelas memiliki contoh yang jauh lebih banyak, disebut kelas mayoritas, sehingga hasil klasifikasi akan bias atau menghasilkan kesalahan klasifikasi.

Pendekatan solusi yang dapat dilakukan dalam menangani permasalahan data dengan kelas tidak seimbang terbagi menjadi dua jenis. Pendekatan pertama diterapkan pada level data atau dikenal dengan *data preprocessing*, yaitu membuat sebaran kelas menjadi seimbang mungkin. Setelah semua kelas memiliki jumlah amatan yang lebih seimbang, maka model klasifikasi standar dapat diterapkan. Pendekatan lainnya dapat dilakukan dengan memodifikasi algoritme pada metode klasifikasi standar sehingga peneliti tidak perlu merubah sebaran kelas yang dimiliki. Modifikasi tersebut dilakukan untuk mengenali contoh di kelas minoritas (Mahdizadeh & Eftekhari, 2013). Kekurangan dari pendekatan ini yaitu dalam menerapkannya bergantung dengan jenis metode klasifikasi dan kesulitan dalam menanganinya (Sahare & Gupta, 2012). Solusi pada level data lebih mudah digunakan dibandingkan dengan pendekatan level algoritme karena gugus data diperbaiki dahulu sebelum diterapkan metode klasifikasi (Chawla, 2009). Selain itu, pendekatan pada level data tidak tergantung pada metode klasifikasi yang dipilih sehingga dapat diterapkan pada semua gugus data untuk melatih metode klasifikasi yang berbeda (Hussein *et al.*, 2019).

Data preprocessing mencakup dua pilihan solusi, yaitu mengeliminasi contoh pada kelas mayoritas (*undersampling*) atau menambah contoh pada kelas minoritas (*oversampling*). (Akbari *et al.*, 2004) mengungkapkan bahwa saat metode *undersampling* dilakukan pada kelas mayoritas, contoh pada kelas mayoritas tersebut tidak lagi bersifat acak. Teknik *oversampling* dipilih pada penelitian ini karena *undersampling* memungkinkan untuk membuang data amatan yang valid dan memberikan informasi penting. *Synthetic Minority Over-sampling Technique* (SMOTE) merupakan salah satu teknik *oversampling* yang populer, diperkenalkan oleh (Chawla *et al.*, 2002). SMOTE membangkitkan data sintesis berdasarkan jumlah tetangga terdekatnya (k -tetangga terdekat). SMOTE menarik banyak perhatian

peneliti sehingga metode tersebut dijadikan sebagai dasar dari perkembangan metode *oversampling* lainnya. *Borderline* SMOTE diusulkan oleh (Han et al., 2005) sebagai teknik *oversampling* yang dapat menyempurnakan SMOTE. Metode ini hanya fokus pada amatan kelas minoritas yang berada di *borderline* atau batas antara kelas mayoritas dan minoritas. Setelah itu, muncul *safe-level* SMOTE pada tahun 2009 yang diperkenalkan oleh (Bunkhumpornpat et al., 2009). Metode *safe-level* SMOTE memiliki beberapa kriteria untuk menentukan apakah data sintetis dapat dibangkitkan atau tidak. Kriteria tersebut dinamakan *safe-level* rasio. Ketika amatan kelas minoritas dan tetangga terdekatnya berada di wilayah yang aman, maka data sintetis dapat dibangkitkan.

Teknik *oversampling* tidak hanya dapat diterapkan pada pengklasifikasi (*classifier*) tunggal, tetapi juga pada beberapa pengklasifikasi. Beberapa *classifier* tunggal dikombinasikan dan hasil prediksi dari masing-masing pengklasifikasi digabungkan melalui proses *voting*. Hal tersebut merupakan konsep dari metode *ensemble*. *Bagging* merupakan salah satu metode *ensemble* yang menggunakan teknik *bootstrap* dalam menghasilkan gugus data baru untuk membuat pengklasifikasi dalam banyak versi. Jika dibandingkan dengan pengklasifikasi tunggal, hasil prediksi *bagging* hampir selalu lebih akurat (Zhou, 2012). Berdasarkan hal tersebut, penelitian ini akan mengkaji performa penerapan metode *bagging* pada algoritme *safe-level* SMOTE berdasarkan metode klasifikasi *Support Vector Machine*. Kajian tersebut dilakukan dengan membandingkan performa hasil metode klasifikasi pada berbagai data simulasi yang dibedakan berdasarkan proporsi ketidakseimbangan kelas. Perbandingan kinerja metode klasifikasi dilakukan berdasarkan tiga kriteria, yaitu akurasi, sensitifitas, dan spesifisitas.

2. Metodologi

2.1 Bahan dan Data

Data yang digunakan pada penelitian ini merupakan data simulasi. Setiap data simulasi memiliki tiga peubah, yaitu dua peubah bebas (X_1 dan X_2) yang bersifat numerik dan satu peubah tidak bebas (Y) yang bersifat kategorik atau dalam hal ini sebagai kelasnya. Amatan pada peubah bebas dibangun berdasarkan sebaran normal ganda, sedangkan amatan pada peubah tidak bebas bersifat bernilai 0 dan 1 yang dibangkitkan secara acak sesuai dengan proporsi amatan yang disajikan pada Tabel 1.

Tabel 1: Proporsi amatan kelas mayoritas dan minoritas

Data	Kelas Mayoritas	Kelas Minoritas
Data 1	95%	5%
Data 2	90%	10%
Data 3	85%	15%

2.2 Ukuran Kinerja Metode Klasifikasi

Perbandingan kinerja metode klasifikasi dilakukan berdasarkan tiga kriteria, yaitu akurasi, sensitifitas, dan spesifisitas. Ketiga ukuran tersebut dapat diperoleh melalui *confusion matrix*, seperti disajikan pada Tabel 2.

Tabel 2: *Confusion matrix*

		Hasil Prediksi	
		Positif	Negatif
Keadaan sesungguhnya	Positif	<i>True Positive (TP)</i>	<i>False Negatif (FN)</i>
	Negatif	<i>False Positive (FP)</i>	<i>True Negatif (TN)</i>

dengan

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN}$$

$$\text{Sensitifitas} = \frac{TP}{TP+FN}$$

$$\text{Spesifisitas} = \frac{TN}{TN+FP}$$

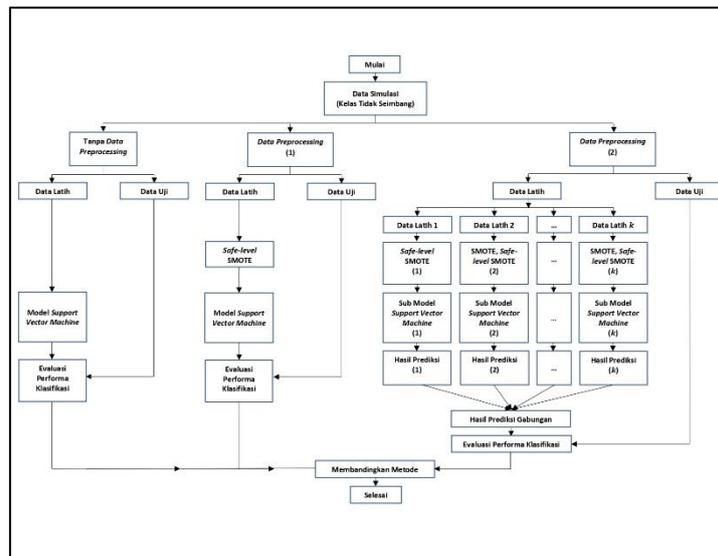
Akurasi memberikan gambaran mengenai tingkat ketepatan metode klasifikasi secara keseluruhan, artinya akurasi menjawab pertanyaan berapa persen amatan yang diklasifikasikan secara benar ke dalam kelas mayoritas dan minoritas dari semua amatan. Sensitifitas mengukur persentase amatan kelas mayoritas yang diklasifikasikan dengan benar dari seluruh amatan yang sesungguhnya berasal dari kelas mayoritas, sedangkan spesifisitas mengukur hal yang tidak diukur oleh sensitifitas sehingga lebih fokus kepada ketepatan dalam memprediksi amatan kelas minoritas.

2.3 *Bagging*

Bagging merupakan singkatan dari *bootstrap aggregating* yang diperkenalkan oleh Breiman pada tahun 1996. Metode *bagging* memiliki dua tahapan dalam analisisnya, yaitu *bootstrap* atau pengambilan contoh dari data contoh (*resampling*) dan *aggregating* atau menggabungkan banyak nilai dugaan menjadi satu nilai dugaan (Sartono & Syafitri, 2010). *SMOTE Bagging* merupakan kombinasi antara metode *Synthetic Minority Oversampling Technique (SMOTE)* dan algoritme *bagging*. *SMOTE Bagging* menerapkan algoritme SMOTE sebelum pemodelan klasifikasi pada setiap gugus data latih (sebanyak k buah) yang diperoleh melalui proses *bootstrap*. Selanjutnya setiap data latih tersebut akan diterapkan metode klasifikasi dan dilakukan proses *aggregating* atau pemilihan suara terbanyak untuk hasil prediksi gabungannya. Berdasarkan prinsip *SMOTE Bagging* tersebut, maka akan diterapkan pula teknik *bagging* pada algoritme *safe-level SMOTE* dengan prosedur pembangkitan data sintetis yang diperkenalkan oleh (Bunghumpornpat et al., 2009). Penerapan *bagging* pada *safe-level SMOTE* selanjutnya disebut sebagai *safe-level SMOTE Bagging* dalam penelitian ini.

2.4 Metode Penelitian

Tahapan analisis yang dilakukan pada penelitian ini disajikan pada Gambar 1 sebagai berikut.



Gambar 1: Diagram alir penelitian

Alur penelitian yang disajikan pada Gambar 1 diterapkan bagi seluruh jenis data simulasi. Gugus data simulasi dibagi menjadi data latih (80 persen) dan data uji (20 persen). Terdapat tiga skema yang diberikan pada setiap data simulasi, yaitu tanpa tahap *data preprocessing* dan melalui tahap *data preprocessing*. *Data preprocessing* (1) menerapkan *safe-level SMOTE*, sedangkan *data preprocessing* (2) menerapkan *safe-level SMOTE Bagging*. Kedua skema tersebut menghasilkan data latih baru yang memuat data sintesis sehingga menjadi lebih seimbang. Selanjutnya metode klasifikasi *Support Vector Machine* dengan kernel radial basis diterapkan pada semua jenis data latih. Pada skema yang melalui *data preprocessing*, hasil prediksi gabungan diperoleh dengan menggabungkan sebanyak k buah prediksi untuk memperoleh prediksi akhir berdasarkan *voting* terbanyak sebagai berikut:

$$H(x) = c_j, \text{ jika } \sum_{i=1}^T h_i^j(x) > \frac{1}{2} \sum_{k=1}^l \sum_{i=1}^T h_i^k(x)$$

dimana c_j merupakan kelas, $h_i^j(x)$ adalah prediksi kelas dari h_i untuk label kelas c_j , $h_i^k(x)$ adalah prediksi untuk semua kelas. c_j adalah prediksi akhir jika *vote* yang dihasilkan lebih dari setengah *vote* semua kelas. Evaluasi performa metode klasifikasi dilakukan menggunakan data uji dengan melihat ukuran akurasi, sensitifitas, dan spesifisitas. Tahap akhir penelitian membandingkan kinerja metode klasifikasi *Support Vector Machine* pada data asli (tanpa *data preprocessing*) dan data yang diproses terlebih dahulu menggunakan *safe-level SMOTE* dan *safe-level SMOTE Bagging*.

3. Hasil dan Pembahasan

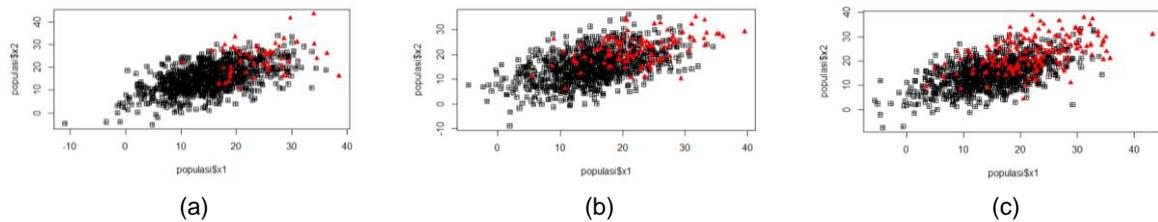
3.1 Deskripsi Data Simulasi

Data peubah bebas dibangkitkan berdasarkan peubah acak normal ganda dan disimbolkan dengan X_1 dan X_2 menggunakan *software R*. Peubah tidak bebas bersifat kategorik dimana 0 merupakan amatan kelas mayoritas dan 1 untuk amatan kelas

minoritas. Jumlah amatan seluruhnya adalah 1000 amatan sehingga banyaknya amatan bagi setiap data simulasi disajikan pada Tabel 3.

Tabel 3: Jumlah amatan kelas mayoritas dan minoritas

Data Simulasi	Kelas Mayoritas (0)	Kelas Minoritas (1)
Data 1	950	50
Data 2	900	100
Data 3	850	150



Gambar 2: Diagram pencar data simulasi dengan proporsi ketidakseimbangan: (a) 95%:5%, (b) 90%:10%, dan (c) 85%:15%.

Penentuan letak amatan kelas mayoritas dan minoritas selanjutnya menjadi perhatian karena hal tersebut berkaitan dengan bagaimana algoritme *safe-level SMOTE* bekerja dalam membangkitkan data sintetis. *Safe-level SMOTE* akan membangkitkan data sintetis di wilayah yang aman. Dalam kondisi amatan kelas mayoritas dan minoritas berjauhan, maka *safe-level SMOTE* memiliki peluang lebih besar dalam membangkitkan data sintetis di wilayah yang berdekatan dengan amatan kelas minoritas lainnya. Hal tersebut berimplikasi pada minimnya kesalahan klasifikasi yang dihasilkan, dibandingkan dengan ketika posisi amatan dari kedua kelas saling berdekatan atau beririsan. Oleh karena itu, peubah bebas dibangkitkan sedemikian rupa agar memiliki sebaran kelas yang beririsan sebagaimana disajikan pada Gambar 2 untuk melihat kinerja dari *safe-level SMOTE*. Amatan berwarna hitam berasal dari kelas mayoritas, sedangkan amatan berwarna merah berasal dari kelas minoritas.

3.2 Metode Klasifikasi Standar

Metode klasifikasi *Support Vector Machine* dengan kernel radial basis diterapkan pada setiap data simulasi dengan kondisi jumlah amatan pada kedua kelas tidak seimbang. Penggunaan kernel dalam metode *Support Vector Machine* ini karena data simulasi yang terbentuk tidak dapat dipisahkan secara linier. Hasil kinerja model klasifikasi *Support Vector Machine* disajikan pada Tabel 4.

Sensitifitas merupakan rasio hasil prediksi benar positif (dalam hal ini 0) dibandingkan dengan keseluruhan data yang benar positif (0). Sensitifitas dapat digunakan ketika kejadian yang diharapkan adalah lebih banyak *false positive* dibandingkan dengan *false negative*, artinya lebih banyak amatan kelas minoritas yang diklasifikasikan ke dalam kelas mayoritas dibandingkan dengan kelas mayoritas yang

diklasifikasikan ke dalam kelas minoritas. Dalam kasus yang sangat serius, kesalahan dalam mengklasifikasikan amatan kelas minoritas ke dalam kelas mayoritas akan menimbulkan masalah yang sangat serius dan kerugian yang sangat besar.

Tabel 4: Kinerja SVM tanpa menyeimbangkan jumlah amatan kedua kelas (%)

Ukuran Kinerja	Data 1	Data 2	Data 3
Akurasi	95,50	94,00	90,00
Sensitifitas	100,00	99,44	99,41
Spesifisitas	10,00	45,00	36,67

Data 2 dan 3 juga masih memberikan nilai sensitifitas yang tinggi, yaitu 99,44 persen dan 99,41 persen. Secara umum seluruh data simulasi memberikan nilai sensitifitas yang tinggi yang berarti bahwa *Support Vector Machine* mampu memberikan keakuratan dalam memprediksi kelas mayoritas. Hal sebaliknya ditunjukkan oleh ukuran spesifisitas. Spesifitas mengukur seberapa akurat metode pengklasifikasi dalam memprediksi amatan kelas minoritas. Berdasarkan data uji, nilai spesifisitas bagi data 1 merupakan yang terendah yaitu hanya 10 persen, artinya hanya 10 persen amatan kelas minoritas yang benar diprediksi sebagai amatan kelas minoritas dibandingkan dengan keseluruhan amatan yang sesungguhnya berasal dari kelas minoritas. Data 2 dan 3 pun menunjukkan nilai spesifisitas yang sangat rendah, walaupun lebih baik dibandingkan dengan data simulasi pertama. Berdasarkan data uji untuk data simulasi ke-2, lebih dari 50 persen amatan kelas minoritas diklasifikasikan sebagai amatan kelas mayoritas, dan 19 dari 30 amatan kelas minoritas pada data simulasi ke-3 diklasifikasikan sebagai kelas mayoritas. Hal ini menunjukkan metode klasifikasi memberikan kinerja yang buruk dalam memprediksi amatan kelas minoritas ketika kondisi kelas tidak seimbang dibiarkan.

3.3 Metode Klasifikasi dengan Penerapan *Safe-level SMOTE*

Skema dengan penerapan *safe-level SMOTE* pada data latih memberikan kinerja metode klasifikasi seperti yang disajikan pada Tabel 5. Data latih yang sebelumnya memiliki kelas dengan jumlah amatan yang tidak seimbang akan ditambah jumlah amatan kelas minoritasnya sehingga memiliki data latih yang baru. Proses penambahan jumlah data buatan atau sintetis pada kelas minoritas untuk masing-masing data simulasi akan menghasilkan data latih baru dengan jumlah yang berbeda. Hal ini disebabkan karena proporsi ketidakseimbangan data awal serta jumlah data latih dan data uji yang bagi setiap data simulasi juga berbeda sehingga penambahan data buattannya yang dihasilkan juga berbeda. Pada tahap ini, jumlah tetangga terdekat yang dipilih adalah sebanyak 5 atau $k = 5$.

Tabel 5: Kinerja SVM dengan menerapkan *safe-level SMOTE* (%)

Ukuran Kinerja	Data 1	Data 2	Data 3
Akurasi	96,00	93,50	90,50
Sensitifitas	100,00	98,89	98,82
Spesifisitas	20,00	45,00	43,33

Berdasarkan Tabel 5, metode *Support Vector Machine* cukup konsisten dalam memberikan akurasi terhadap ketiga data simulasi. Data 1 memiliki tingkat keakuratan yang lebih tinggi (96 persen) dibandingkan dengan data yang sebelumnya tidak seimbang. Hal yang sama juga terjadi bagi data 3 dimana tingkat keakuratan yang diperoleh sebesar 90,50 persen, sedangkan data 2 memiliki tingkat akurasi sebesar 93,50 persen. Ukuran kerja klasifikasi akurasi dan sensitifitas dapat dipertimbangkan pada tahap ini karena data latih telah diterapkan proses penyeimbangan data menggunakan *safe-level SMOTE*. Kinerja *Support Vector Machine* dalam memprediksi amatan kelas mayoritas sangat baik. Tingkat sensitifitas metode klasifikasi bagi data 1 menunjukkan keakuratan yang sempurna yaitu 100 persen, sedangkan bagi data 2 dan 3 adalah 98.89 persen dan 98.82 persen.

Berdasarkan data uji, tingkat spesifisitas bagi ketiga data simulasi masih sangat rendah. Data 1 memiliki tingkat spesifisitas sebesar 20 persen. Rendahnya nilai tersebut disebabkan karena 80 persen amatan yang sesungguhnya berasal dari kelas minoritas diklasifikasikan sebagai amatan kelas mayoritas. Data 2 memiliki tingkat spesifisitas yang sama dengan kondisi data awal dimana tidak diaplikasikannya *safe-level SMOTE* yaitu sebesar 45 persen. Tingkat spesifisitas yang diperoleh data 3 lebih tinggi dibandingkan sebelumnya yaitu sebesar 43,33 persen, tetapi hal tersebut masih menunjukkan kemampuan metode klasifikasi dalam memprediksi amatan kelas minoritas masih rendah. Kondisi sebaran data yang beririsan antara kelas mayoritas dan minoritas kemungkinan besar menghasilkan data buatan yang masih sangat berdekatan dengan kelas mayoritas sehingga hasil klasifikasinya masih dimungkinkan mengalami kesalahan.

3.4 Metode Klasifikasi dengan Penerapan *Bagging* pada *Safe-level SMOTE*

Tahap ini merupakan gabungan antara metode *safe-level SMOTE* dan *bagging* dimana proses *bootstrap* akan diterapkan pada setiap data latih yang dihasilkan oleh data simulasi. Proses *bootstrap* akan menghasilkan himpunan data latih baru yang akan digunakan untuk membuat model klasifikasi menggunakan *Support Vector Machine*. Kinerja metode *Support Vector Machine* pada tahap ini disajikan pada Tabel 6. Proses *bootstrap* dilakukan sebanyak 50 kali sehingga akan diperoleh hasil prediksi dengan jumlah yang sama yaitu sebanyak 50 data uji bagi setiap data simulasi.

Tabel 6: Kinerja SVM dengan menerapkan *safe-level SMOTE Bagging* (%)

Ukuran Kinerja	Data 1	Data 2	Data 3
Akurasi	96,46	93,30	93,22
Sensitifitas	100,00	100,00	99,26
Spesifisitas	77,93	78,46	85,69

Kinerja metode klasifikasi yang diterapkan *safe-level SMOTE* menunjukkan hasil yang baik. Akurasi bagi ketiga data simulasi masih menunjukkan angka yang tinggi, yaitu 96,46 persen bagi data simulasi ke-1, 93,30 persen bagi data ke-2, dan 93,22 persen bagi data ke-3. Tingkat sensitifitas yang dihasilkan pun menunjukkan angka yang tinggi bagi semua data simulasi. Data 1 dan 2 memiliki tingkat sensitifitas sebesar 100 persen yang berarti bahwa kemampuan metode klasifikasi dalam memprediksi

amatan kelas mayoritas sudah sangat baik dan tidak terjadi kesalahan klasifikasi. Data 3 memberikan tingkat sensitifitas yang sedikit lebih rendah dibandingkan dengan Data 1 dan Data 2, akan tetapi nilai yang dihasilkan masih sangat baik dan mendekati 100 persen, yaitu sebesar 99,26 persen. Ukuran kinerja metode klasifikasi yang mengalami peningkatan signifikan adalah spesifisitas. Dengan penerapan *safe-level SMOTE Bagging*, metode *Support Vector Machine* mampu mengklasifikasikan amatan kelas minoritas ke dalam kelas yang seharusnya dengan lebih baik. Tingkat spesifisitas bagi data 1 adalah sebesar 77,93 persen. Perbaikan tingkat spesifisitas juga ditunjukkan di data 2 dan 3. Lebih dari 80 persen amatan kelas minoritas telah diklasifikasikan dengan benar pada data simulasi ke-2. Hal tersebut menghasilkan tingkat spesifisitas yang jauh lebih tinggi dibandingkan sebelumnya yaitu menjadi sebesar 78,46 persen. Tingkat spesifisitas yang tertinggi berasal dari data simulasi ke-3 dimana jumlah amatan minoritasnya paling banyak. Pada data 3 juga ditemukan lebih dari 80 persen amatan kelas minoritas yang diklasifikasikan ke dalam kelas yang sesungguhnya sehingga menghasilkan tingkat spesifisitas yang tinggi, yaitu sebesar 85,69 persen.

3.5 Perbandingan Kinerja Metode Klasifikasi

Kondisi kelas tidak seimbang memberikan pengaruh kepada beberapa ukuran kinerja model klasifikasi. Nilai akurasi yang dihasilkan oleh semua data simulasi, baik tanpa penerapan *safe-level SMOTE* maupun *safe-level SMOTE Bagging*, sangat tinggi. Apabila hasil ini dijadikan sebagai satu-satunya ukuran kinerja metode klasifikasi akan sangat membahayakan karena amatan kelas minoritas memberikan kontribusi yang sangat sedikit dalam perhitungan akurasi. Sensitifitas lebih fokus kepada hasil prediksi kelas mayoritas dimana cenderung lebih memilih salah dalam mengklasifikasikan amatan kelas minoritas ke dalam kelas mayoritas dibandingkan dengan sebaliknya. Spesifisitas lebih memilih terjadinya *false negative* dibandingkan *false positive*, akan tetapi dalam kondisi data tidak seimbang kesalahan dalam mengklasifikasikan amatan kelas minoritas menjadi kelas mayoritas dalam jumlah yang banyak akan berdampak pada pengambilan keputusan di berbagai bidang. Oleh karena itu, spesifisitas menjadi ukuran yang sangat penting dalam menentukan kinerja metode klasifikasi.

Tabel 7: Perbandingan ukuran kinerja klasifikasi (%)

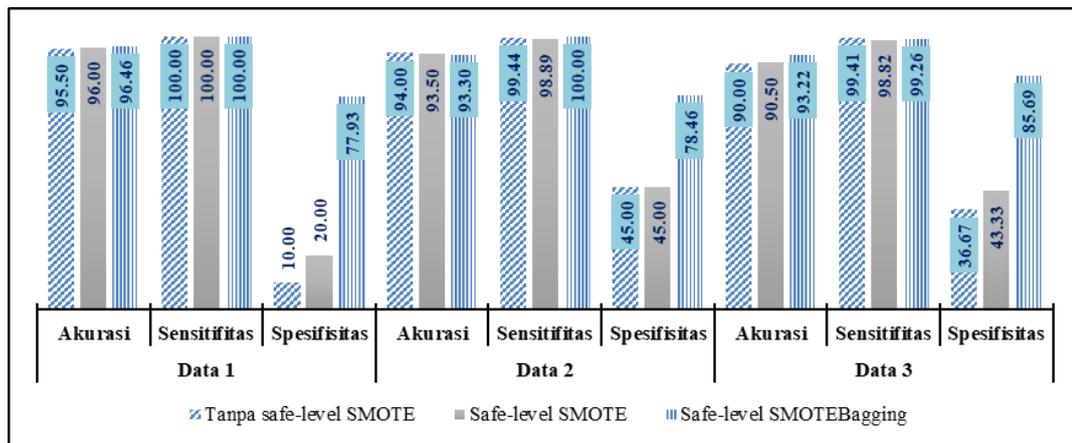
Metode	Data 1			Data 2			Data 3		
	A	B	C	A	B	C	A	B	C
Tanpa <i>safe-level SMOTE</i>	95,50	100,00	10,00	94,00	99,44	45,00	90,00	99,41	36,67
<i>Safe-level SMOTE</i>	96,00	100,00	20,00	93,50	98,89	45,00	90,50	98,82	43,33
<i>Safe-level SMOTE Bagging</i>	96,46	100,00	77,93	93,30	100,00	78,46	93,22	99,26	85,69

Keterangan: A = akurasi, B = sensitifitas, C = spesifisitas.

Tabel 7 menunjukkan keseluruhan hasil yang dilakukan pada penelitian ini. Secara umum, nilai akurasi dan sensitifitas pada seluruh data simulasi di ketiga kondisi, yaitu tanpa penerapan *safe-level SMOTE*, adanya penerapan *safe-level SMOTE* dan *safe-level SMOTE Bagging*, yang dihasilkan oleh metode *Support Vector Machine* tidak

mengalami perubahan yang signifikan. Keduanya bernilai sangat tinggi karena jumlah amatan kelas mayoritas memiliki kontribusi yang sangat besar di dalamnya. Oleh karena itu, satu-satunya ukuran yang dapat dijadikan sebagai pembanding adalah spesifisitas.

Gambar 3 menunjukkan bahwa ketika metode klasifikasi langsung diterapkan pada data dengan kelas tidak seimbang, maka nilai spesifisitas yang dihasilkan dari data uji sangat rendah. Tingkat spesifisitas mengalami kenaikan ketika *safe-level* SMOTE mulai diterapkan ke dalam data latih, artinya kedua kelas akan memiliki jumlah amatan yang lebih seimbang. Kenaikan spesifisitas sebesar 10 persen terjadi di data 1 dan 6,67 persen terjadi pada data 3 ketika *safe-level* SMOTE diterapkan, sedangkan spesifisitas di data 2 tidak mengalami perubahan.



Gambar 3: Perbandingan performa *Support Vector Machine*

Penerapan metode *safe-level* SMOTEBagging berhasil memperbaiki kinerja metode klasifikasi *Support Vector Machine*. Hal ini dapat terlihat dari besarnya peningkatan spesifisitas yang terjadi pada semua data simulasi. Tingkat spesifisitas yang diperoleh ketika *bagging* diterapkan untuk setiap data simulasi adalah 77,93 persen bagi data 1, 78,46 persen bagi data 2, dan 85,69 persen bagi data 3. Peningkatan terbesar terjadi pada data 1 (57,93 persen) dimana proporsi kelas minoritasnya paling kecil, sedangkan peningkatan yang diperoleh dari skema penerapan *safe-level* SMOTE tanpa *bagging* bagi data simulasi 2 dan 3 secara berturut-turut adalah 33,46 persen dan 42,36 persen. Hasil ini menunjukkan bahwa *majority voting* yang dilakukan pada proses *bootstrap* dan *aggregating* membuat kinerja *Support Vector Machine* jauh lebih baik dibandingkan dengan sebelumnya.

4. Simpulan dan Saran

Spesifisitas menjadi ukuran yang diutamakan dalam menentukan kinerja metode klasifikasi karena mampu mengukur tingkat keakuratan dalam memprediksi kelas minoritas yang menjadi perhatian. Metode *Support Vector Machine* yang diterapkan pada data latih yang tidak mendapatkan penanganan kelas tidak seimbang memiliki tingkat keakuratan dan sensitifitas yang tinggi bagi ketiga jenis data simulasi, namun memberikan tingkat spesifisitas yang sangat rendah. Spesifisitas semakin meningkat ketika jumlah amatan kedua kelas mulai seimbang akibat diterapkannya *safe-level*

SMOTE. Kinerja metode *Support Vector Machine* yang paling baik dalam memprediksi amatan kelas minoritas ditunjukkan ketika data latih dari setiap data simulasi diterapkan *bootstrap* dan *aggregating (Bagging)*. Hasil yang diperoleh tersebut konsisten bagi seluruh data simulasi dimana sebaran data antara kedua kelas saling beririsan.

Pengembangan yang dapat dilakukan dari penelitian ini adalah dengan mengkaji metode *safe-levelSMOTEBagging* pada data *real* sehingga teruji konsistensi performanya. Selain itu, variabel yang akan dilibatkan memiliki skala pengukuran yang berbeda sehingga metode klasifikasi yang diterapkan juga lebih bervariasi. Dengan begitu diharapkan kajian dalam penanganan kelas tidak seimbang akan semakin komprehensif.

Ucapan Terima Kasih. Terima kasih kepada Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Negeri Jakarta yang telah memberikan dukungan dalam penelitian ini.

Daftar Pustaka

- Aggarwa, C. C. (2015). *Data Classification: Algorithms and Applications*. Chapman & Hall/CRC Data Mining and Knowledge Discovery Series.
- Akbani, R., Kwek, S., & Japkowicz, N. (2004). Applying support vector machines to imbalanced datasets. *European Conference on Machine Learning*, 39–50. Springer.
- Bunkhumpornpat, C., Sinapiromsaran, K., & Lursinsap, C. (2009). Safe-level-smote: Safe-level-synthetic minority over-sampling technique for handling the class imbalanced problem. *Pacific-Asia Conference on Knowledge Discovery and Data Mining*, 475–482. Springer.
- Chawla, N. V. (2009). Data mining for imbalanced datasets: An overview. *Data Mining and Knowledge Discovery Handbook*, 875–886.
- 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.
- Han, H., Wang, W.-Y., & Mao, B.-H. (2005). Borderline-SMOTE: a new over-sampling method in imbalanced data sets learning. *International Conference on Intelligent Computing*, 878–887. Springer.
- Hanifah, F. S., Wijayanto, H., & Kurnia, A. (2015). Smotebagging algorithm for imbalanced dataset in logistic regression analysis (case: Credit of bank x). *Applied Mathematical Sciences*, 9(138): 6857–6865.
- He, H., & Garcia, E. A. (2009). Learning from imbalanced data. *IEEE Transactions on Knowledge and Data Engineering*, 21(9): 1263–1284.
- Hussein, A. S., Li, T., Yohannese, C. W., & Bashir, K. (2019). A-SMOTE: A new preprocessing approach for highly imbalanced datasets by improving SMOTE. *International Journal of Computational Intelligence Systems*, 12(2): 1412–1422.

- Japkowicz, N. (2000). Learning from imbalanced data sets: a comparison of various strategies. *AAAI Workshop on Learning from Imbalanced Data Sets*, 68:10–15. AAAI Press Menlo Park, CA.
- Mahdizadeh, M., & Eftekhari, M. (2013). Designing fuzzy imbalanced classifier based on the subtractive clustering and genetic programming. *2013 13th Iranian Conference on Fuzzy Systems (IFSC)*, 1–6. IEEE.
- Sahare, M., & Gupta, H. (2012). A review of multi-class classification for imbalanced data. *International Journal of Advanced Computer Research*, 2(3): 160-164.
- Sartono, B., & Syafitri, U. D. (2010). Metode pohon gabungan: Solusi pilihan untuk mengatasi kelemahan pohon regresi dan klasifikasi tunggal. *Forum Statistika Dan Komputasi*, 15(1): 1-7.
- Zhou, Z.-H. (2012). *Ensemble methods: foundations and algorithms*. CRC press.