

KOMPARASI METODE *OVERSAMPLING* UNTUK KLASIFIKASI TEKS UJARAN KEBENCIAN

Naufal Azmi Verdikha¹⁾, Teguh Bharata Adji²⁾, Adhistya Erna Permanasari³⁾

^{1), 2), 3)} Departemen Teknik Elektro dan Teknologi Informasi,
Fakultas Teknik, Universitas Gadjah Mada

Jl. Grafika No.2, Kampus UGM, Yogyakarta 55281

Email : naufal.ti14@mail.ugm.ac.id¹⁾, adji@ugm.ac.id²⁾, adhistya@ugm.ac.id³⁾

Abstrak

Fasilitas yang diberikan oleh jaringan media sosial dapat memberikan kebebasan bagi penggunaannya untuk saling berkomunikasi. Namun, kebebasan yang tidak dibatasi dapat memberikan kesempatan bagi penggunaannya untuk menyerang seseorang atau sebuah organisasi dengan menggunakan ujaran kebencian. Oleh karena itu, dibutuhkan sistem klasifikasi teks untuk mengatasi ujaran kebencian yang terdapat di jaringan media sosial. Untuk membuat sebuah sistem klasifikasi tersebut, diperlukan sebuah data latih berupa teks ujaran kebencian yang terdapat di jaringan media sosial. Akan tetapi, teks ujaran kebencian tersebut susah ditemukan yang dimana hal ini dapat membuat distribusi data latih menjadi tidak seimbang (*imbalanced data*). Terdapat beberapa metode untuk menyelesaikan masalah *imbalanced data*, salah satunya dengan menggunakan metode *oversampling*. Penelitian ini bertujuan untuk membandingkan lima metode *oversampling* yaitu SMOTE, Borderline-SMOTE ver.1, Borderline-SMOTE ver.2, SMOTE-SVM dan metode *oversampling* ADASYN untuk klasifikasi teks ujaran kebencian menggunakan metode pembobotan TF-IDF dan metode klasifikasi SVM. Hasil penelitian menunjukkan bahwa dengan menggunakan metode *oversampling* SMOTE mampu mengatasi masalah *imbalanced data* lebih baik dibandingkan dengan metode lainnya yang terdapat pada penelitian ini.

Kata kunci: *Imbalanced data*, klasifikasi teks, *oversampling*, SVM.

1. Pendahuluan

Jaringan media sosial telah menjadi sebuah wadah dimana setiap orang dapat saling berbagi pikiran. Fasilitas yang diberikan oleh jaringan media sosial memberikan kebebasan bagi penggunaannya untuk saling berkomunikasi. Akan tetapi, kebebasan yang tidak dibatasi dapat menyebabkan penggunaannya untuk menyerang seseorang atau sebuah kelompok dengan menggunakan ujaran kebencian. Hal ini telah dilarang berdasarkan hukum internasional yang telah diterbitkan

oleh Office of the United Nations High Commissioner for Human Rights (OHCHR). Hukum tersebut mengatur dengan tegas bahwa segala tindakan yang menganjurkan kebencian atas dasar kebangsaan, ras atau agama, atau hasutan untuk melakukan diskriminasi, permusuhan atau kekerasan harus dilarang [1]. Media sosial seperti Twitter dan Facebook telah menerapkan kebijakan mengenai konten-konten yang mengandung ujaran kebencian. Cara penerapan kebijakan masih dianggap kurang mampu menghapus konten-konten ujaran kebencian tersebut [2].

Oleh karena itu, dibutuhkan sistem klasifikasi teks yang mampu mendeteksi ujaran kebencian yang terdapat di jaringan media sosial. Untuk membuat sebuah sistem klasifikasi teks tersebut, diperlukan sebuah data latih berupa teks ujaran kebencian. Akan tetapi, teks ujaran kebencian tersebut susah ditemukan yang dimana hal ini dapat menyebabkan distribusi data latih untuk sistem klasifikasi tersebut menjadi tidak seimbang (*imbalanced data*). Klasifikasi dengan menggunakan *imbalanced data* dapat menyebabkan dampak buruk terhadap kinerja klasifikasi tersebut. Klasifikasi cenderung fokus ke kelas yang memiliki jumlah sampel lebih besar (kelas mayoritas) dan akan cenderung mengabaikan kelas yang memiliki jumlah sampel yang lebih sedikit (kelas minoritas). Walaupun nilai akurasi dari sistem klasifikasi tersebut tinggi, tetapi sebagian besar sistem mengklasifikasi dengan benar pada kelas mayoritas. Oleh sebab itu nilai akurasi tidak dapat dijadikan sebuah nilai evaluasi untuk sistem klasifikasi yang mempunyai data latih yang tidak seimbang [3].

Terdapat dua solusi pendekatan untuk mengatasi *imbalanced data*, yaitu solusi pendekatan internal dan solusi pendekatan eksternal. Solusi pendekatan internal bertujuan untuk memperkecil tingkat kesalahan (*error rate*) dengan cara membuat sebuah algoritma baru atau memodifikasi algoritma yang sudah ada tanpa merubah jumlah data sampel. Sedangkan solusi pendekatan eksternal bekerja dengan merubah jumlah data sampel (*resampling*) yang ada pada dataset sebelum diproses kedalam algoritma klasifikasi. Di dalam beberapa kasus, solusi pendekatan internal cukup efektif dalam meningkatkan kinerja sistem klasifikasi, akan tetapi

solusi ini membuat algoritma tersebut menjadi lebih spesifik. Hal ini dapat menjadi sebuah masalah jika menggunakan *dataset* yang memiliki karakteristik yang berbeda-beda dimana *dataset* tersebut dapat diklasifikasikan lebih baik oleh algoritma klasifikasi yang lain. Berbeda dengan solusi pendekatan eksternal yang tidak bergantung kepada algoritma klasifikasi yang digunakan, oleh karena itu solusi pendekatan eksternal dapat dikatakan lebih serba guna dibandingkan solusi pendekatan internal [4].

Teknik *resampling* secara umum terbagi dua, yaitu *oversampling* dan *undersampling*. *Oversampling* merubah data sampel dengan cara menambah data sampel yang terdapat pada kelas minoritas dengan cara membuat replika data sampel tersebut hingga distribusi data sampel menjadi lebih seimbang. Sebaliknya, *undersampling* merubah data sampel dengan cara mengeliminasi data sampel yang terdapat pada kelas mayoritas hingga distribusi data sampel menjadi lebih seimbang.

Terdapat beberapa penelitian yang menggunakan solusi pendekatan eksternal untuk mengatasi masalah *imbalanced data* untuk klasifikasi teks. Liu [5] melakukan penelitian tentang pengaruh metode *resampling* dalam proses klasifikasi *imbalanced data* pada data teks. Dengan menggunakan metode pembobotan *Term Frequency-Inverse Document Frequency* (TF-IDF) dan beberapa *classifier* yaitu *Multinomial Naïve Bayes*, *k Nearest Neighbor* (kNN) dan *Support Vector Machines* (SVM) pada 8 *dataset* yang berbeda. Penelitian tersebut menunjukkan bahwa *classifier Multinomial Naïve Bayes* mengalami kenaikan performa yang paling signifikan setelah di *resampling* diantara *classifier* yang lain, akan tetapi *classifier SVM* memiliki nilai evaluasi performa yang lebih unggul dibandingkan *classifier* yang lain.

Penelitian Wenando, dkk [6] menggunakan salah satu metode *oversampling* yaitu *Synthetic Minority Oversampling Technique* (SMOTE) untuk menyeimbangkan *dataset* yang terbatas untuk klasifikasi teks yang digunakan untuk mendeteksi tingkat pemahaman mahasiswa dalam proses *Prior Knowledge Activation*. Di dalam penelitian tersebut menggunakan metode pembobotan TF-IDF yang kemudian dibandingkan dengan beberapa *classifier*, yaitu *Bayesian Network*, *Naïve Bayes*, SVM dan *Multilayer Perceptron*. Hasil penelitian menunjukkan bahwa algoritma *classifier Multilayer Perceptron* dan SVM yang telah dikombinasikan dengan metode SMOTE memiliki peningkatan nilai evaluasi yang lebih dominan dibandingkan dengan algoritma *classifier* lainnya.

Penelitian Ah-Pine, dkk [7], melakukan komparasi metode *oversampling* untuk sentimen analisis Twitter. Metode *oversampling* yang digunakan yaitu SMOTE, *Borderline-SMOTE* dan *Adaptive Synthetic* (ADASYN). Metode-metode *oversampling* tersebut digunakan pada

3 *dataset* Tweet yang dimana *dataset* tersebut memiliki dua kelas (*binary class*) yaitu kelas positif dan kelas negatif yang kemudian diklasifikasikan menggunakan metode CART dan *II logistic regression*. Penelitian tersebut menunjukkan bahwa ketiga metode *oversampling* tersebut mampu mengatasi masalah *imbalanced data* dengan peningkatan model dalam mengenali data sampel kelas minoritas serta mendapatkan peningkatan untuk nilai evaluasi *Geometric Means*.

Penelitian ini bertujuan untuk membandingkan metode-metode *oversampling* yang digunakan untuk klasifikasi teks ujaran kebencian. Metode-metode *oversampling* yang digunakan yaitu metode *oversampling* SMOTE [3], *Borderline-SMOTE* [8] versi 1 dan 2, SMOTE-SVM [9] dan metode *oversampling* ADASYN [10]. Metode-metode *oversampling* tersebut digunakan untuk menyeimbangkan *Dataset Tweet Hatepeech* yang telah dikumpulkan dan diberikan label sebelumnya oleh Waseem, dkk [11]. *Dataset* tersebut berisi sekumpulan data tweet yang berlabelkan rasisme, seksisme dan data tweet yang bukan termasuk kedua kriteria tersebut. Penelitian ini menggunakan metode pembobotan TF-IDF dan metode klasifikasi SVM. Hasil klasifikasi akan dievaluasi menggunakan nilai evaluasi *Geometric Mean*.

2. Pembahasan

Dataset

Dataset yang digunakan adalah *Dataset Tweet Hatepeech* yang berasal dari penelitian Waseem, dkk [11]. *Dataset* tersebut berisi data tweet ujaran kebencian yang berlabelkan *racism* (rasisme) berjumlah 1.970 tweet, *sexism* (seksisme) berjumlah 3.378 tweet dan *none* (bukan tergolong keduanya) berjumlah 11.559 tweet. Pengambilan data tweet menggunakan salah satu *crawler* tweet Python : *Tweepy*.

Pra Proses

Pra proses merupakan tahapan awal pada klasifikasi teks untuk mempersiapkan data teks agar lebih terstruktur sehingga dapat diproses dengan baik di tahapan klasifikasi. Berikut ini adalah tahapan-tahapan pra proses:

1. Menghapus data tweet yang error pada saat pengambilan data. Tweet error disebabkan oleh beberapa hal seperti tweet tidak dapat diakses atau telah dihapus oleh penggunanya.
2. Menghapus atribut tweet seperti *Retweet* ('RT'), *hashtag* ('#'), *tagging* ('@'), *emoticon* dan *link url*.
3. Menghapus karakter non-alfanumerik.
4. *Case Folding* : digunakan untuk mengubah semua huruf besar menjadi huruf kecil.
5. *Tokenizing* : memisahkan kata-kata yang terdapat pada kalimat-kalimat di tweet menjadi kata tunggal

(unigram). Dari hasil *tokenizing* didapatkan jumlah fitur teks berupa kata tunggal sebesar 15.312 fitur.

Setelah mengalami tahapan-tahapan tersebut, *dataset* mengalami pengurangan jumlah data. Jumlah data sampel *dataset* setelah mengalami tahapan-tahapan tersebut dapat dilihat pada Tabel 1 berikut:

Tabel 1. Tabel *dataset* setelah mengalami beberapa tahapan pra proses.

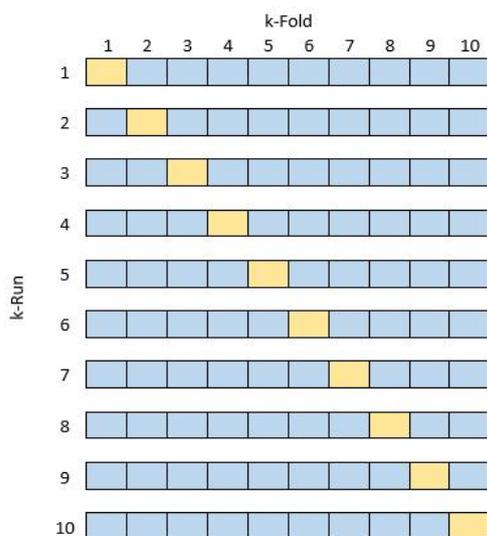
Label	Jumlah Tweet
racism	1.923
sexism	3.119
none	10.701
Total Data	15.743

Pembobotan Bag of Words (BOW)

Fitur yang dihasilkan dari tahapan sebelumnya kemudian direpresentasikan dalam bentuk *Bag of Words* (BOW). Hasil representasi dari metode pembobotan ini berbentuk matrik berdimensi besar, dimana baris matrik adalah dokumen tweet *d* dan kolom matrik adalah fitur berupa kata-kata unik *t*. Nilai dari sebuah fitur untuk sebuah dokumen *d* dibentuk berdasarkan nilai bobot dari jumlah frekuensi kata atau fitur *t* yang muncul didalam dokumen tersebut. Nilai bobot ini juga disebut nilai *term frequency* (TF). Tahapan BOW di penelitian ini menghasilkan matrik berdimensi 15.743 x 15.312.

Pemisahan Data Fold

Pemisahan data dilakukan untuk membagi data uji dan data latih. Penelitian ini menggunakan *10-fold cross validation* untuk mengevaluasi kinerja klasifikasi. *Dataset* dipisah menjadi 10 *fold* seperti yang ditunjukkan pada gambar 1, dimana data uji berada di *fold* berwarna kuning dan data latih di *fold* berwarna biru.



Gambar 1. 10 Cross Validation

Di pengujian pertama (*1-Run*), *fold* pertama digunakan untuk data uji dan 9 *fold* lainnya menjadi data latih. Di

pengujian kedua (*2-Run*), *fold* kedua digunakan untuk data uji dan 9 *fold* lainnya menjadi data latih. Proses ini akan berlanjut hingga pengujian kesepuluh (*10-Run*). Di setiap *fold* memiliki jumlah data sampel kelas yang sama, yakni 10% dari setiap kelas *racism*, *sexism* dan *none*, dan di setiap *fold* memiliki data sampel yang berbeda.

Oversampling

Proses *oversampling* dilakukan setelah proses pemisahan data *fold* selesai. Proses *oversampling* hanya dilakukan pada *fold* data latih dan tidak dilakukan pada *fold* data uji. Hal ini dilakukan untuk menghindari keadaan *overfitting* pada saat proses evaluasi kinerja klasifikasi. Proses *oversampling* penelitian ini dilakukan pada data sampel kelas *racism* dan kelas *sexism*. Proses *oversampling* dilakukan dengan menggunakan modul bahasa pemrograman Python : *imbalanced-learn* [12]. Parameter metode-metode *oversampling* yang digunakan adalah parameter *default* dari modul tersebut.

Tabel 2. Tabel waktu tempuh proses *oversampling*.

Metode	Waktu (detik)
SMOTE	7,657
<i>Borderline-SMOTE ver.1</i>	10,463
<i>Borderline-SMOTE ver.2</i>	10,568
SMOTE-SVM	44,445
ADASYN	7,987

Tabel 2 menunjukkan rata-rata hasil waktu tempuh metode-metode *oversampling* dalam memproses *fold* data latih di setiap pengujian *k-Run*. Metode SMOTE memiliki waktu tempuh yang paling cepat dalam melakukan proses *oversampling* pada data latih yaitu 7,657 detik. Metode *Borderline-SMOTE* versi 1 dan 2 memiliki rata-rata waktu tempuh yang hampir sama yaitu sekitar 10 detik. Metode SMOTE versi SVM memiliki waktu tempuh yang paling lama diantara metode *oversampling* yang lain, yaitu 44,445 detik untuk setiap proses *oversampling* pada data latih di setiap pengujian *k-Run*. Sedangkan metode ADASYN memiliki waktu tempuh yang sedikit lambat dengan metode SMOTE yaitu 7,987 detik

Pembobotan Term Frequency - Inverse Document Frequency (TF-IDF)

Setelah data latih di setiap pengujian *k-Run* telah di *oversampling*, fitur data latih dan data uji yang berbentuk BOW kemudian dibobotkan menggunakan metode pembobotan *Term Frequency-Inverse Document Frequency* (TF-IDF). Nilai TF-IDF didapatkan dengan cara mengalikan nilai TF dan nilai IDF. Nilai DF adalah jumlah dokumen tweet yang mengandung setidaknya satu kata atau satu fitur *t* didalam keseluruhan dokumen. Untuk mencari nilai IDF didapatkan dari persamaan 1 berikut :

$$IDF_t = \log\left(\frac{N}{DF_t}\right) \dots(1)$$

Dimana N adalah total jumlah dokumen. Sehingga nilai bobot TF-IDF (W_t) didapatkan dari persamaan 2 berikut:

$$W_t = TF_{td} \times \log\left(\frac{N}{DF_t}\right) \dots(2)$$

Besarnya dimensi matrik yang dihasilkan dari pembobotan ini berbeda dengan besar dimensi yang dihasilkan pada tahapan pembobotan BOW. Hal ini dikarenakan *dataset* telah dipisah menjadi beberapa *fold* data dan masing-masing *fold* data memiliki jumlah dokumen yang berbeda-beda.

Klasifikasi SVM

Penelitian ini menggunakan metode klasifikasi *Support Vector Machines* (SVM). Dikarenakan *dataset* pada penelitian ini mempunyai tiga kelas (*multiclass*), metode SVM pada penelitian ini menggunakan kernel linier dengan strategi *one-vs-rest* [13]. Terdapat enam proses klasifikasi pada penelitian ini. Proses pertama melibatkan *dataset* original, dimana *dataset* ini adalah *dataset* asli tanpa menggunakan metode *oversampling*. Sedangkan kelima proses lainnya melibatkan *dataset* yang telah di *oversampling*, masing-masing *dataset* tersebut dinamakan sesuai dengan metode *oversampling* yang digunakan. Keenam hasil proses klasifikasi kemudian dievaluasi di tahapan evaluasi.

Evaluasi

Tahapan ini akan mengevaluasi kinerja dari klasifikasi yang telah dibuat sebelumnya. Untuk mengetahui seberapa handal model klasifikasi pada penelitian ini dalam mengenali sampel-sampel data didalam kelas yang berbeda, penelitian ini menggunakan metode evaluasi matrik konfusi. Tabel 3 menunjukkan format tabel matriks konfusi.

Tabel 3. Tabel format matriks konfusi.

	Predicted Positive	Predicted Negative
Actual Positive	TP	FN
Actual Negative	FP	TN

Untuk mengevaluasi kinerja klasifikasi pada *imbalanced data* tidak dapat menggunakan nilai akurasi, dimana nilai evaluasi akurasi menempatkan lebih banyak bobot pada kelas mayoritas, yang mempersulit *classifier* untuk memproses dengan baik pada kelas minoritas.

Terdapat evaluasi matrik yang dapat menilai kinerja klasifikasi pada *imbalanced data*, yaitu *Geometric Mean* (Geo) [14]. Geo adalah sebuah nilai evaluasi untuk sebuah akurasi prediksi untuk kedua kelas. Geo menggunakan nilai evaluasi matrik sensitivitas dan spesifisitas, dimana kedua nilai evaluasi tersebut mengukur nilai akurasi dari sampel positif dan negatif. Nilai yang dihasilkan Geo mengindikasikan keseimbangan antara kinerja klasifikasi pada kelas

mayoritas dan kelas minoritas. Jika terdapat nilai akurasi yang rendah pada sampel positif, maka nilai Geo akan rendah walaupun terdapat nilai akurasi yang tinggi pada sampel negatif, hal ini berlaku juga untuk keadaan sebaliknya.

Untuk mendapatkan nilai evaluasi matrik sensitivitas dapat dihitung dengan persamaan 3 berikut :

$$\text{sensitivitas} = \frac{TP}{TP+FN} \dots(3)$$

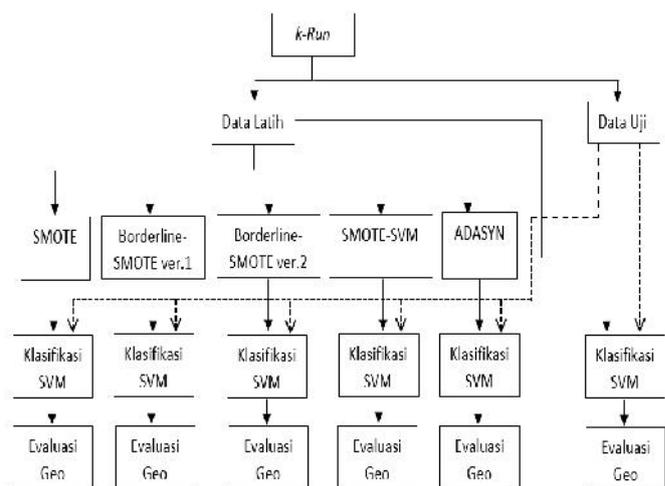
Untuk mendapatkan nilai evaluasi matrik spesifisitas dapat dihitung dengan persamaan 4 berikut :

$$\text{spesifisitas} = \frac{TN}{TN+FP} \dots(4)$$

Setelah mendapatkan nilai evaluasi matrik sensitivitas dan spesifisitas, nilai evaluasi Geo dapat dihitung dengan persamaan 5 berikut :

$$\text{Geo} = \sqrt{\text{sensitivitas} \times \text{spesifisitas}} \dots(5)$$

Proses evaluasi kinerja klasifikasi di penelitian ini dapat dilihat pada gambar 2 berikut :

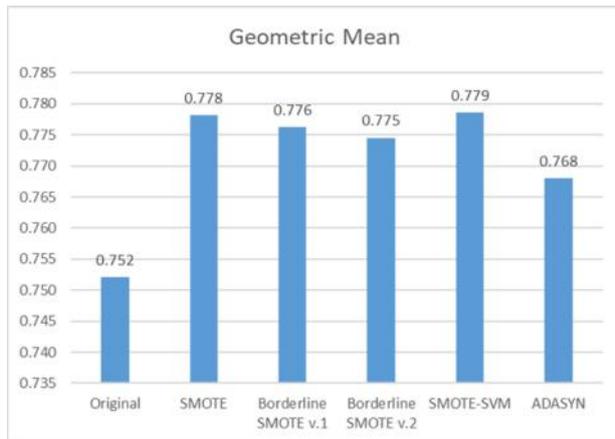


Gambar 2. Proses evaluasi

Gambar 2 menunjukkan tahapan-tahapan menuju proses evaluasi. Terdapat 6 evaluasi yang akan dibandingkan di penelitian ini. 6 evaluasi tersebut melibatkan 6 proses klasifikasi yang menggunakan satu *dataset* original dan 5 *dataset* hasil *oversampling*. Keenam evaluasi tersebut dilakukan sebanyak 10 kali pengujian atau *10-Run* dengan data latih dan data uji yang berbeda-beda, atau bisa disebut dengan *10-fold cross validation*. Hasil dari nilai-nilai evaluasi Geo tiap klasifikasi dihitung nilai rata-ratanya menggunakan *macro average*. Adapun hasil nilai *macro average* Geo tiap klasifikasi dapat dilihat pada Tabel 4 berikut :

Tabel 4. Tabel nilai macro average Geo.

Metode	Geo
Original	0,752
SMOTE	0,778
<i>Borderline-SMOTE ver.1</i>	0,776
<i>Borderline-SMOTE ver.2</i>	0,775
SMOTE-SVM	0,779
ADASYN	0,768



Gambar 3. Diagram nilai Geo

Tabel 4 menunjukkan nilai evaluasi kinerja klasifikasi berdasarkan nilai evaluasi Geo. Metode SMOTE memiliki peningkatan kinerja klasifikasi sebesar 2,6 %. Metode *Borderline-SMOTE* versi 1 dan versi 2 memiliki peningkatan kinerja klasifikasi yang tidak jauh berbeda, yakni 2,4 % dan 2,3 %. Metode SMOTE-SVM memiliki peningkatan kinerja klasifikasi sebesar 2,7 %. Sedangkan metode ADASYN memiliki peningkatan kinerja klasifikasi sebesar 1,6 %. Gambar 3 menunjukkan bahwa SMOTE-SVM memiliki kinerja yang lebih baik dibandingkan metode *oversampling* lainnya. Sedangkan metode ADASYN memiliki nilai evaluasi terendah dibandingkan metode *oversampling* yang lain.

3. Kesimpulan

Kelima metode *oversampling* pada penelitian ini terbukti mampu meningkatkan kinerja klasifikasi untuk teks ujaran kebencian dengan *dataset* yang memiliki *multiclass*. Berdasarkan hasil pengamatan, metode *oversampling* SMOTE-SVM memiliki nilai kinerja yang lebih unggul dibandingkan metode *oversampling* lainnya, akan tetapi metode SMOTE-SVM memiliki waktu tempuh terlama dalam melakukan proses *oversampling* dibandingkan metode *oversampling* lainnya. Di sisi lain metode SMOTE memiliki waktu tempuh lebih cepat dibandingkan metode SMOTE-SVM dan memiliki kinerja klasifikasi yang tidak jauh berbeda. Oleh karena itu metode SMOTE dapat dianggap metode yang lebih unggul diantara metode *oversampling* lainnya yang terdapat pada penelitian ini.

Penelitian selanjutnya dapat menggunakan metode *resampling* lain, yaitu kombinasi *oversampling* dan *undersampling* untuk mengatasi masalah *imbalanced data* pada klasifikasi teks ujaran kebencian.

Daftar Pustaka

- [1] "International Covenant on Civil and Political Rights." [Online]. Available: <http://www.ohchr.org/en/professionalinterest/pages/ccpr.aspx>. [Accessed: 15-Nov-2017].
- [2] T. Davidson, D. Warmsley, M. Macy, and I. Weber, "Automated Hate Speech Detection and the Problem of Offensive Language," *Proc. 11th Int. AAAI Conf. Web Soc. Media*, no. Icws, pp. 512–515, 2017.
- [3] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, "SMOTE: Synthetic minority over-sampling technique," *J. Artif. Intell. Res.*, vol. 16, pp. 321–357, 2002.
- [4] A. Estabrooks, T. Jo, and N. Japkowicz, "A Multiple Resampling Method for Learning from Imbalanced Data Sets," *Comput. Intell.*, vol. 20, no. 1, pp. 18–36, Feb. 2004.
- [5] A. C. Liu, "The Effect of Oversampling and Undersampling on Classifying Imbalanced Text Datasets," University of Texas at Austin, 2004.
- [6] F. A. Wenando, T. B. Adji, and I. Ardiyanto, "Text Classification to Detect Student Level of Understanding in Prior Knowledge Activation Process," *Adv. Sci. Lett.*, vol. 23, no. 3, pp. 2285–2287, Mar. 2017.
- [7] J. Ah-Pine and E. P. S. Morales, "A study of synthetic oversampling for twitter imbalanced sentiment analysis," *CEUR Workshop Proc.*, vol. 1646, pp. 17–24, 2016.
- [8] H. Han, W. Wang, and B. Mao, "Borderline-SMOTE: A New Over-Sampling Method in Imbalanced Data Sets Learning," 2005, pp. 878–887.
- [9] H. M. Nguyen, E. W. Cooper, and K. Kamei, "Borderline Over-Sampling for Imbalanced Data Classification," *Int. J. Knowl. Eng. Soft Data Paradig.*, vol. 3, no. 1, p. 4, 2011.
- [10] H. He, Y. Bai, E. A. Garcia, and S. Li, "ADASYN: Adaptive synthetic sampling approach for imbalanced learning," *2008 IEEE Int. Jt. Conf. Neural Networks (IEEE World Congr. Comput. Intell. Hong Kong)*, pp. 1322–1328, 2008.
- [11] Z. Waseem and D. Hovy, "Hateful Symbols or Hateful People? Predictive Features for Hate Speech Detection on Twitter," *Proc. NAACL Student Res. Work.*, pp. 88–93, 2016.
- [12] G. Lemaitre, F. Nogueira, and C. K. Aridas, "Imbalanced-learn: A Python Toolbox to Tackle the Curse of Imbalanced Datasets in Machine Learning," *CoRR*, vol. abs/1609.0, pp. 1–5, 2016.
- [13] S. S. Keerthi, S. Sundararajan, K.-W. Chang, C.-J. Hsieh, and C.-J. Lin, "A sequential dual method for large scale multi-class linear svms," in *Proceeding of the 14th ACM SIGKDD international conference on Knowledge discovery and data mining - KDD 08*, 2008, p. 408.
- [14] M. Kubat and S. Matwin, "Addressing the Curse of Imbalanced Training Sets: One Sided Selection," *Icml*, vol. 97, pp. 179–186, 1997.

Biodata Penulis

Naufal Azmi Verdikha, memperoleh gelar Sarjana Komputer (S.Kom), Jurusan Teknik Informatika STMIK AMIKOM Yogyakarta, lulus tahun 2014. Memperoleh gelar Magister Komputer (M.Kom) Saat ini sedang menempuh Program Pasca Sarjana Magister Teknologi Informasi Universitas Gadjah Mada Yogyakarta.

Teguh Bharata Adji, peneliti dan dosen di Fakultas Teknik Universitas Gadjah Mada Yogyakarta. Memperoleh gelar Doctor of Philosophy (Ph.D) di

Department of Computer and Information Science, Universiti Teknologi Petronas, Perak, Malaysia pada tahun 2010. Memperoleh gelar Master of Engineering (M.Eng) di Department of Electrical Engineering, Faculty of Engineering, Doshisha University, Kyoto, Jepang pada tahun 2001. Memperoleh gelar Master of Engineering (M.T) di Departemen Teknik Elektro dan Teknologi Informasi, Fakultas Teknik, Universitas Gadjah Mada, Yogyakarta pada tahun 1998. Memperoleh gelar Sarjana Teknik (S.T) di Departemen Teknik Elektro dan Teknologi Informasi, Fakultas Teknik, Universitas Gadjah Mada, Yogyakarta pada tahun 1995.

Adhitya Erna Permanasari, peneliti dan dosen di Fakultas Teknik Universitas Gadjah Mada Yogyakarta. Memperoleh gelar Doctor of Philosophy (Ph.D) di Department of Computer and Information Science, Universiti Teknologi Petronas, Perak, Malaysia pada tahun 2010. Memperoleh gelar Master of Engineering (M.T) di Departemen Teknik Elektro dan Teknologi Informasi, Fakultas Teknik, Universitas Gadjah Mada, Yogyakarta pada tahun 2006. Memperoleh gelar Sarjana Teknik (S.T) di Departemen Teknik Elektro dan Teknologi Informasi, Fakultas Teknik, Universitas Gadjah Mada, Yogyakarta pada tahun 2003.