
IDENTIFIKASI OTOMATIS PESAN SAKSI MATA PADA MEDIA SOSIAL SAAT BENCANA GEMPA

Sarah Monika Nooralifa¹, Mohammad Reza Faisal², Friska Abadi³, Radityo Adi
Nugroho⁴, Muliadi⁵

¹²³⁴⁵Ilmu Komputer FMIPA ULM
Jl. A. Yani Km 36 Banjarbaru, Kalimantan Selatan
Email: sarahmnalifa@gmail.com

Abstract

Social media platforms such as Twitter make it easy for users to share and receive critical information on disasters and emergencies. Information from eyewitnesses can be useful for law enforcement agencies and humanitarian organizations. Identification disaster messages on Twitter can also be used as information that can be used to see the current situation. In several research studies, earthquake disasters are divided into three categories: eyewitnesses, non-eye witnesses, and do not know. Meanwhile, the feature extraction that used in this research is bag-of-words that produce high-dimensional data output. The purpose of this research is to utilize lexicon-based feature extraction to produce low-dimensional data. However, there has never been the use of Lexicon based on the multiclass classification in cases of natural disasters. The features built by the Lexicon-based are far less, namely 2-15 features. This research was divided into two steps, namely the first step was carried out without combining Lexicon and the second step was carried out by combining Lexicon. The highest accuracy produced by the combination of Barasa SentiwordNet, Bing Liu, NRC, AFINN, and Heeryon Cho's Lexicon using the Support Vector Machine classification with an accuracy of 64.13% with a total of 15 features.

Keywords: *Lexicon Based, Support Vector Machine, Classification, Text Mining, Twitter, Disasters*

Abstrak

Platform media sosial seperti Twitter memudahkan para pengguna untuk berbagi dan menerima informasi penting selama bencana dan keadaan darurat. Informasi dari saksi mata dapat berguna bagi lembaga penegak hukum dan organisasi kemanusiaan. Pesan bencana di Twitter juga dapat digunakan sebagai informasi yang digunakan untuk mengetahui situasi yang sedang berlangsung. Pada beberapa riset yang telah dilakukan oleh peneliti, tweet bencana gempa dibagi menjadi tiga kategori yaitu eyewitness, non-eyewitness, dan don't know. Sedangkan ekstraksi fitur yang digunakan pada riset-riset tersebut adalah bag-of-words yang menghasilkan keluaran berupa data berdimensi tinggi. Tujuan penelitian ini adalah memanfaatkan ekstraksi fitur berbasis lexicon untuk menghasilkan data berdimensi rendah. Namun belum pernah ada pemanfaatan Lexicon Based untuk klasifikasi multiclass pada kasus klasifikasi pesan bencana alam. Fitur yang dihasilkan oleh Lexicon based jauh lebih sedikit yaitu 2-15 fitur. Penelitian ini dibagi menjadi dua tahap, yaitu tahap pertama dilakukan tanpa penggabungan kamus Lexicon dan tahap kedua dilakukan dengan menggabungkan kamus Lexicon. Akurasi tertinggi dihasilkan oleh kombinasi Barasa SentiwordNet, Bing Liu, NRC, AFINN, dan Lexicon Heeryon Cho menggunakan klasifikasi Support Vector Machine dengan akurasi sebesar 64,13% dengan jumlah fitur sebanyak 15 fitur.

Kata kunci: *Lexicon based, Support Vector Machine, Klasifikasi, Text Mining, Twitter, Bencana Alam*

1. PENDAHULUAN

Bencana dapat dikategorikan menjadi dua faktor yaitu, faktor alam dan non alam. Deteksi tentang adanya bencana merupakan yang cukup krusial, bahkan dapat menyelamatkan nyawa. Bila seseorang mengetahui akan ada bencana beberapa detik saja sebelum bencana terasa, maka waktu itu dapat digunakan untuk hal penting. Dalam peristiwa seperti ini, *social network sensor* dapat secara efektif berfungsi sebagai sumber informasi utama dari saksi mata, serta media untuk penyebarannya dan menjadi alternatif yang menarik untuk metode deteksi bencana. Hal ini dapat diterapkan untuk identifikasi saksi mata yang mengalami bencana gempa, sebagai informasi dan peringatan dini untuk wilayah lain. Twitter dapat menjadi salah satu tempat untuk berbagi dan menerima informasi penting selama bencana dan keadaan darurat. Informasi dari pengamat dan saksi mata dapat berguna bagi lembaga penegak hukum dan organisasi kemanusiaan, informasi pesan bencana yang didapat melalui twitter juga dapat digunakan untuk informasi yang dapat dipercaya tentang situasi yang sedang berlangsung untuk mendapatkan kesadaran situasional di antara pengguna media sosial lainnya. Informasi biasanya mencakup laporan dari orang luka-luka dan tewas, kebutuhan mendesak masyarakat yang terkena dampak, laporan hilang dan orang ditemukan, dan laporan kerusakan, dan lain-lain. Menurut penelitian yang dilakukan oleh Zahra (2019) [1] yang berjudul *Automatic identification of eyewitness messages on twitter during disasters*, disebutkan bahwa terdapat 3 kelas untuk mengidentifikasi sumber tweet yaitu *eyewitness*, *non-eyewitness*, dan *don't know*.

Lexicon Based salah satu dari algoritma ekstraksi fitur yang terdiri dari beberapa kamus, diantaranya adalah SentiwordNet, Bing Liu Lexicon, AFINN Lexicon, OpinionFinder, Senti-Strength, HBE Lexicon, NRC Emotion Lexicon, dan lain-lain. Pada penelitian yang dilakukan oleh Heeryon Cho, Jong-Seok Lee dan Songkuk Kim (2013) [2] dengan judul *Enhancing Lexicon-Based Review Classification by Merging and Revising Sentiment Dictionaries*, Data menggunakan 90.000 review buku dari amazon, digunakan 8 kamus lexicon. Kemudian menggabungkan sentimen resource, kamus yang digabungkan dan direvisi menunjukkan kinerja terbaik (80,9%).

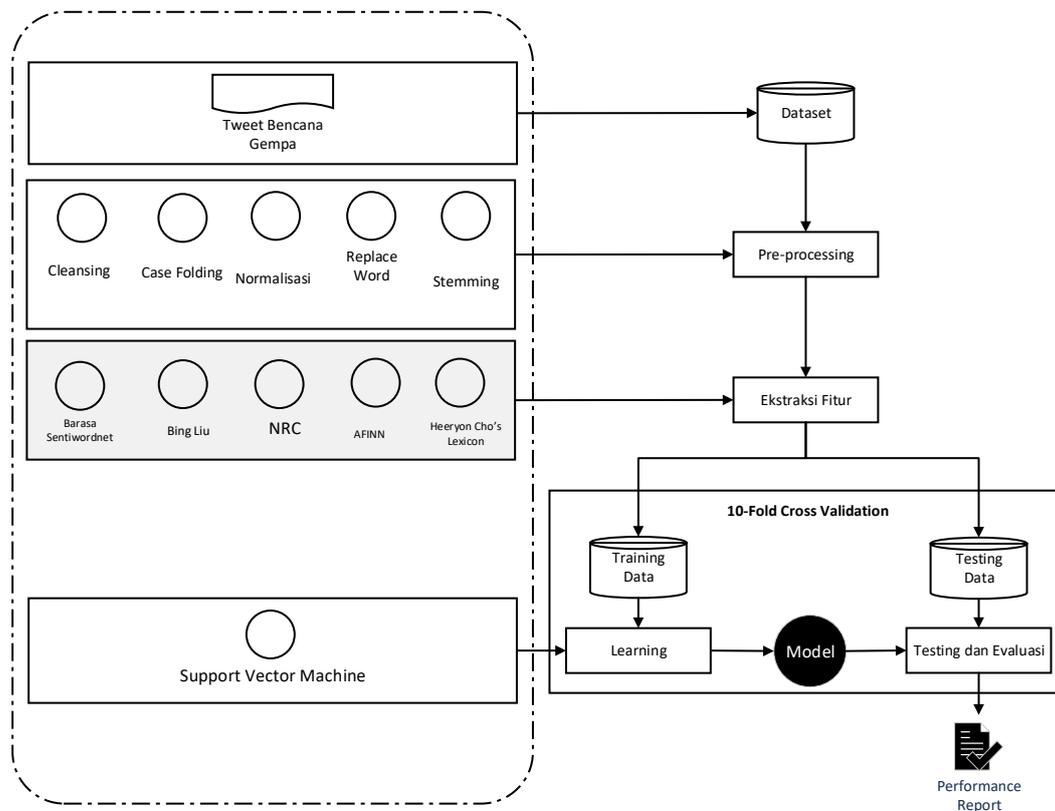
Penelitian yang dilakukan oleh Mahendrajaya (2019) [3] dengan judul *Analisis Sentimen Pengguna Gopay Menggunakan Metode Lexicon Based dan Support Vector Machine*, menggunakan *Lexicon Based* dengan kamus positif negatif Bing Liu klasifikasi model SVM dan mendapatkan akurasi yang cukup baik sebesar 89,17%. Pada penelitian yang dilakukan oleh Kurniawan (2019) [4] dengan judul *Analisis Sentimen Opini Film Menggunakan Metode Naïve Bayes dan Lexicon Based Features*. Pengujian metode *Naïve Bayes* dan *lexicon based* yang menggunakan kamus Barasa milik David Moeljadi dihasilkan nilai akurasi sebesar 80%. Pada penelitian yang dilakukan oleh Gaikwan (2016) [5] dengan judul *Multiclass Mood Classification on Twitter Using Lexicon Dictionary and Machine Learning Algorithms*. menggunakan basis data leksikon AFINN untuk menetapkan *Impact Factor* pada setiap kata, SVM terbukti lebih unggul dari KNN dan NB dengan akurasi maksimum 82% dan terendah 77%. Pada penelitian yang dilakukan oleh Rohman (2019) [6] dengan judul *Deteksi Emosi Media Sosial Menggunakan Pendekatan Leksikon dan Natural Language Processing*. Hasil validasi terdapat 16 update status atau 61,53% label emosinya akurat.

Pada penelitian sebelumnya, hanya digunakan salah satu kamus *lexicon* yang sudah dimodifikasi ke Bahasa Indonesia. Hal ini ada kemungkinan kata-kata yang ada pada data

tidak terdapat pada kamus tersebut. Untuk saling melengkapi maka dapat dilakukan gabungan beberapa lexicon. Pada penelitian ini menggunakan Lexicon Based sebagai algoritma ekstraksi fitur dengan gabungan 4 jenis kamus Lexicon yang berbeda yaitu Bahasa SentiwordNet, Bing, NRC, dan AFINN. Dan *Support Vector Machine* (SVM) sebagai klasifikasi karena pada beberapa penelitian sebelumnya menghasilkan tingkat akurasi yang cukup baik. Untuk data yang digunakan dalam penelitian ini adalah tweet yang langsung di *crawling* dari Twitter dengan menggunakan RapidMiner Studio.

2. METODOLOGI PENELITIAN

Adapun prosedur pada penelitian ini adalah sebagai berikut:



Gambar 1. Alur Penelitian

2.1. Pengumpulan dan pelabelan data

Data yang digunakan pada penelitian kali ini adalah data informasi bencana gempa yang diambil dari API Twitter menggunakan RapidMiner Studio dengan keyword “gempa”, “gempa bumi”, dan “#gempa”. Menurut penelitian yang dilakukan oleh Zahra (2019) yang berjudul *Automatic identification of eyewitness messages on twitter during disasters*,

disebutkan bahwa terdapat 3 kelas untuk mengidentifikasi sumber tweet yaitu *eyewitness*, *non-eyewitness*, dan *don't know*.

Kemudian dilakukan pemberian label secara manual dengan membaca setiap tweet sehingga didapat 1000 tweet untuk setiap kelas. Total data yang digunakan pada penelitian ini adalah 3000 tweet. Data dapat diunduh pada link berikut ini <https://github.com/rezafaisal/NaturalDisasterOnTwitter>.

2.2. Pre-Processing

a. Cleansing

Merupakan tahapan pembersihan tweet dari noise berupa username (@), angka, Retweet, RT, HTML, link, hastag (#), emoticon, dan tanda baca lainnya seperti “,!\$%^&*”.

b. Case folding

Merupakan tahapan mengubah semua huruf kapital (*uppercase*) pada sebuah kata atau kalimat menjadi huruf kecil (*lowercase*)

c. Normalisasi

Merupakan tahapan memperbaiki ejaan dan mengubah kata yang tidak baku menjadi Bahasa Indonesia yang benar.

d. Replace word

Replace word merupakan tahapan merubah kata-kata asing menjadi Bahasa Indonesia seperti “stay safe” menjadi “tetap aman” dan memperpendek kata-kata yang berlebihan seperti “gempaaaa” menjadi “gempa”.

e. Stemming

Merupakan tahapan penguraian bentuk kata menjadi kata dasar (prefix, sufiks, dan konfiks), tujuannya untuk menghilangkan kata imbuhan.

2.3. Ekstraksi Fitur dengan *Lexicon Based*

Proses ekstraksi fitur dilakukan menggunakan metode *Lexicon Based* dengan cara menghitung skor sentimen. Selanjutnya setiap fitur kata yang mengandung skor dalam kalimat tersebut dijumlahkan untuk mendapatkan total skor pada sebuah kalimat.

2.4. Klasifikasi

Setelah proses ekstraksi fitur menggunakan metode *Lexicon Based* kemudian akan masuk proses klasifikasi, dengan metode *Support Vector Machine* sebagai klasifikasi dokumen untuk analisis sentimen dengan bahasa pemrograman R. Dalam penelitian ini analisis akan menggunakan SVM *multiclass* dengan pendekatan *One Versus One* (1v1) menggunakan package *Kernlab* dengan kernel *Radial Basis Function* (RBF) dan dengan parameter *default* (Cost C = 1).

2.5. Evaluasi

Evaluasi merupakan pengukuran terhadap kinerja sistem klasifikasi. Kinerja sistem klasifikasi menggambarkan seberapa baik sistem dalam mengklasifikasikan data. Pada penelitian kali ini evaluasi akan diukur menggunakan akurasi (rasio prediksi benar dengan keseluruhan data) menggunakan *Confusion Matrix*.

Tabel 1. Tabel *Confusion Matrix*

Prediksi	Aktual		
	Eyewitness	Non-eyewitness	Don't know
Eyewitness	P-EE (TP)	P-NE	P-DE
Non-eyewitness	P-EN	P-NN (TP)	P-DN

Don't know	P-ED	P-ND	P-DD (TP)
------------	------	------	-----------

Keterangan dari tabel *Confusion matrix* adalah sebagai berikut:

- P-EE: jumlah prediksi dimana *eyewitness* terprediksi benar sebagai *eyewitness (True Positive)*
- P-NE: jumlah prediksi dimana *eyewitness* terprediksi salah sebagai *non-eyewitness*
- P-DE: jumlah prediksi dimana *eyewitness* terprediksi salah sebagai *don't know*
- P-EN: jumlah prediksi dimana *non-eyewitness* terprediksi salah sebagai *eyewitness*
- P-NN: jumlah prediksi dimana *non-eyewitness* terprediksi benar sebagai *non eyewitness (True Positive)*
- P-DN: jumlah prediksi dimana *non-eyewitness* terprediksi salah sebagai *don't know*
- P-ED: jumlah prediksi dimana *don't know* terprediksi salah sebagai *eyewitness*
- P-ND: jumlah prediksi dimana *don't know* terprediksi salah sebagai *non- eyewitness*
- P-DD: jumlah prediksi dimana *don't know* terprediksi benar sebagai *don't know (True Positive)*

Tabel 2. Tabel Rumus Akurasi

Rumus	$\frac{\text{Jumlah data yang benar (TP)}}{\text{Jumlah seluruh data}} \times 100$
-------	--

2.6. Performance Report

Tahap dari laporan performa berupa aksi dari hasil analisis yang didapat, tahapan ini dilakukan visualisasi dan presentasi hasil pengetahuan yang diperoleh. Visualisasi dari laporan performa dapat disajikan dalam bentuk tabel atau grafik dari hasil analisis yang didapat.

3. HASIL DAN PEMBAHASAN

3.1. Hasil

- Barasa SentiwordNet

Merunut Kurniawan (2019) [4] kamus Barasa didapatkan dari proses generasi *file barasa.py* menggunakan Anaconda Prompt kemudian dilanjutkan ke proses ekstraksi fitur menggunakan Python. Nilai yang akan dijadikan bobot adalah nilai sentimen yang dihitung dengan perhitungan jumlah nilai skor dari 0.0 sampai 1.0 untuk masing-masing fitur yaitu PosScore atau NegScore kemudian dibagi dengan total keseluruhan nilai skor dari PosScore dan NegScore untuk pembobotan masing-masing kata. Pada langkah pertama ekstraksi fitur, setiap kata di tweet dicocokkan dengan set data Barasa SentiwordNet dan jika cocok maka ditemukan kata itu ditambahkan sebagai fitur dengan perhitungan skor sebagai berikut:

$$\text{sum_PosScore}(kata) = \sum_{n=1}^n \text{PosScore}(kata)$$

$$\text{sum_NegScore}(kata) = \sum_{n=1}^n \text{NegScore}(kata)$$

Perhitungan nilai total dari PosScore dan NegScore dari suatu kata adalah sebagai berikut:

$$\text{total_score} = \text{sum_PosScore} + \text{sum_NegScore}$$

Perhitungan nilai sentimen suatu kata pada kelas positif dan kelas negatif adalah sebagai berikut:

$$\text{senti_score_pos} = \frac{\text{sum_PosScore}(kata)}{\text{total_score}}$$

$$senti_score_neg = \frac{sum_NegScore(kata)}{total_score}$$

Tabel 3. Penerapan Kamus Barasa SentiwordNet

Text	PosScore	NegScore	Label
pantas goyang goyang gempa ternyata	0.48375451263537905	0.516245487364621	eyewitness
rumah di sukabumi rusak akibat gempa bumi antara news jawa barat	0.30487804878048785	0.6951219512195123	Non-eyewitness
help rt kaos tie dye stok only pcs untuk setiap motif siapa cepat dia dapat selengkapnya cek dibawah gempa	0.6727272727272727	0.3272727272727272	Don't know

b. Bing Liu

Skor pada Bing Liu adalah positif (+1) dan negatif (-1). Ekstraksi Fitur dilakukan menggunakan bahasa pemrograman R, pada langkah pertama ekstraksi fitur, setiap kata di tweet dicocokkan dengan set data Bing Liu dan jika cocok maka ditemukan kata itu dan ditambahkan sebagai fitur. Selanjutnya setiap fitur kata yang mengandung skor dalam kalimat tersebut dijumlahkan untuk mendapatkan total skor pada sebuah kalimat.

Tabel 4. Penerapan Kamus Bing Liu

Text	Score	Label
pantas goyang goyang gempa ternyata	0	eyewitness
rumah di sukabumi rusak akibat gempa bumi antara news jawa barat	-1	Non-eyewitness
help rt kaos tie dye stok only pcs untuk setiap motif siapa cepat dia dapat selengkapnya cek dibawah gempa	1	Don't know

c. NRC

NRC mencakup delapan emosi yaitu *joy, surprise, sadness, trust, anger, fear, disgust, dan anticipation* dan ditambah dua kelas sentimen, yaitu positif dan negatif. Ekstraksi Fitur dilakukan menggunakan bahasa pemrograman R, pada langkah pertama ekstraksi fitur, setiap kata di tweet dicocokkan dengan set data NRC yang berdasarkan pada delapan emosi dan dua kelas positif-negatif. Jika cocok maka ditemukan kata itu dan ditambahkan sebagai fitur, contohnya kata "gempa" mencakup emosi *fear* sehingga ditambahkan nilai 1 pada sentimen *fear*. Selanjutnya setiap fitur kata yang mengandung skor dalam kalimat tersebut dijumlahkan untuk mendapatkan total skor pada sebuah kalimat.

Tabel 5. Penerapan Kamus NRC

Text	Fear	Positive	Trust	Anger	Anticipation	Disgust	Negatif	Sadness	Joy	Surprise	Label
pantas goyang goyang gempa ternyata	1	1	1	0	0	0	0	0	0	0	Eye-witness
rumah di sukabumi rusak akibat gempa bumi antara news jawa barat	4	0	0	3	1	2	3	3	0	0	Non Eye-witness
help rt kaos tie dye stok only pcs untuk setiap motif siapa cepat dia dapat selengkapnya cek	1	3	0	0	1	0	0	0	0	1	Don't know

dibawah gempa

d. AFINN

Skor pada AFINN berkisar dari - 5 (sangat negatif) hingga + 5 (sangat positif) dalam bilangan bulat. Pada penelitian ini kamus AFINN ditranslasikan ke Bahasa Indonesia dengan score yang sama pada tiap kalimatnya. Ekstraksi Fitur dilakukan menggunakan bahasa pemrograman R, pada langkah pertama ekstraksi fitur, setiap kata di tweet dicocokkan dengan set data AFINN dan jika cocok maka ditemukan kata itu dan ditambahkan sebagai fitur. Selanjutnya setiap fitur kata yang mengandung skor dalam kalimat tersebut dijumlahkan untuk mendapatkan total skor pada sebuah kalimat.

Tabel 6. Penerapan Kamus AFINN

Text	Score	Label
pantas goyang goyang gempa ternyata	0	eyewitness Non-
rumah di sukabumi rusak akibat gempa bumi antara news jawa barat help rt kaos tie dye stok only pcs untuk setiap motif siapa cepat dia dapat	-1	eyewitness Don't know
selengkapnya cek dibawah gempa	2	

e. *Lexicon* Heeryon Cho

Kamus ini adalah satu kamus tambahan yang merupakan seluruh gabungan kata dari kamus *Lexicon Based* yang mengacu pada penelitian Heeryon Cho (2013). Pada tahap ini dilakukan penggabungan seluruh kata dari kamus Barasa SentiwordNet, Bing Liu, NRC, dan AFINN. Penggabungan seluruh kata pada kamus dilakukan agar bisa menghasilkan akurasi yang lebih baik. Sebelum digabungkan, dilakukan standarisasi skor untuk kamus *Lexicon*, standarisasi yang dilakukan adalah sebagai berikut:

1. Barasa SentiwordNet

Skor awal Barasa Sentiwordnet nilai PosScore yang lebih tinggi akan distandarisasi menjadi (+1) dan nilai NegScore yang lebih tinggi akan distandarisasi menjadi (-1)

2. Bing liu

Skor kamus Bing Liu tetap, yaitu positif (+1) dan negatif (-1)

3. NRC

Skor awal NRC yang terdiri dari *Positive, Anticipation, Joy, Surprise*, dan *trust* akan distandarisasi menjadi (+1) dan *Negative, Anger, Disgust, Fear*, dan *Sadness* akan distandarisasi menjadi (-1)

4. AFINN

Skor awal AFINN yang berkisar (-5) hingga (-1) akan distandarisasi menjadi (-1) dan skor awal yang berkisar (+1) hingga (+5) akan distandarisasi menjadi (+1).

Ekstraksi Fitur dilakukan menggunakan bahasa pemrograman R, pada langkah pertama ekstraksi fitur, setiap kata di *tweet* dicocokkan dengan set data *Combined Lexicon* dan jika cocok maka ditemukan kata itu dan ditambahkan sebagai fitur. Selanjutnya setiap fitur kata yang mengandung skor dalam kalimat tersebut dijumlahkan untuk mendapatkan total skor pada sebuah kalimat.

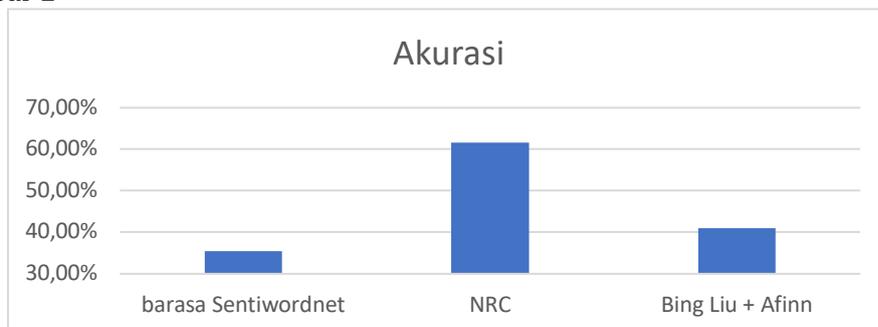
Tabel 7. Penerapan Kamus *Combined Lexicon*

Text	Score	Label
pantas goyang goyang gempa ternyata	-3	eyewitness Non-
rumah di sukabumi rusak akibat gempa bumi antara news jawa barat help rt kaos tie dye stok only pcs untuk setiap motif siapa cepat dia dapat	-1	eyewitness Don't know
	0	Don't know

selengkapnya cek dibawah gempa

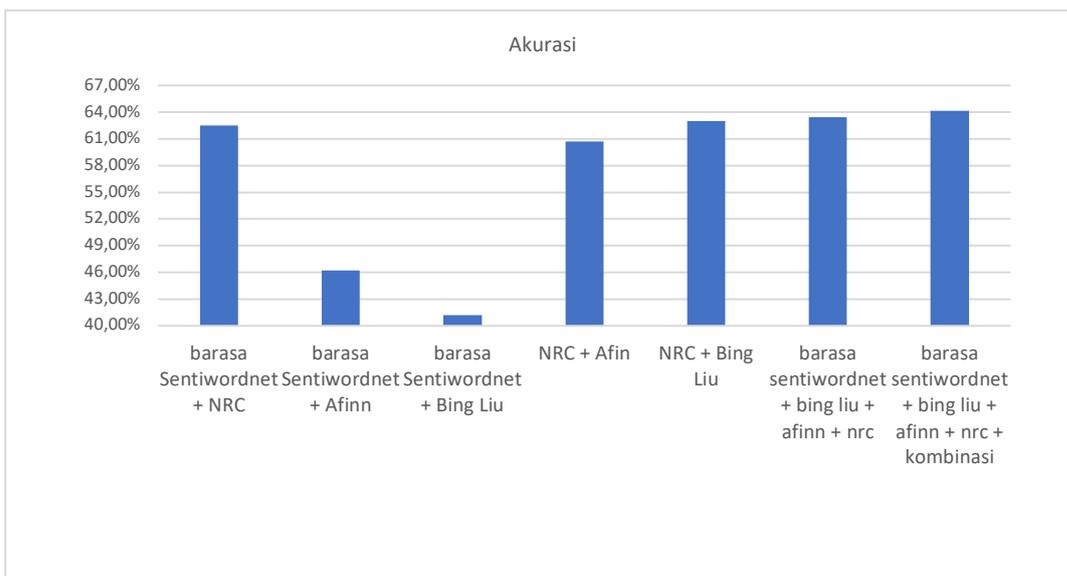
Akan dilakukan dua tahap pengujian yaitu klasifikasi perbandingan pada kamus *Lexicon Based*, kemudian klasifikasi pada penggabungan kamus *Lexicon Based*. Klasifikasi yang digunakan dalam penelitian ini adalah menggunakan metode SVM sebagai klasifikasi dokumen untuk analisis sentimen dengan bahasa pemrograman R. Dalam penelitian ini analisis akan menggunakan fungsi SVM *multiclass* dengan *One-Versus-One Approach* menggunakan *package* Kernlab dengan kernel *Radial Basis Function* (RBF) dan dengan parameter default (Cost C = 1). Pengujian dilakukan dengan 3000 data yang telah melalui tahap *pre-processing* dan ekstraksi fitur. Untuk melakukan pengujian ini maka dibagi menjadi data latih menggunakan *k-fold cross validation* dengan k = 10 sehingga terbagi data sebanyak 2700 untuk data latih dan 300 untuk data uji. Pada 2700 data latih memiliki 900 data dengan label *eyewitness*, 900 data dengan label *non-eyewitness* dan 900 data dengan label *don't know*. Sementara 300 data uji terdiri dari 100 data dengan label *eyewitness*, 100 data dengan label *non-eyewitness* dan 100 data dengan label *don't know*.

Hasil dari perbandingan antar kamus *Lexicon Based* akan disajikan pada grafik dalam Gambar 2



Gambar 2. Grafik hasil akurasi SVM dalam proses pengujian perbandingan kamus *Lexicon*

Hasil dari penggabungan antar kamus *Lexicon Based* akan disajikan pada grafik dalam Gambar 3



Gambar 3. Grafik hasil akurasi SVM dalam proses pengujian penggabungan kamus *Lexicon*

3.2. Pembahasan

Hasil dari perhitungan akurasi dalam proses pengujian perbandingan kamus Barasa SentiwordNet menggunakan klasifikasi SVM, dihasilkan akurasi sebesar 35,43%. Proses pengujian kamus NRC menggunakan klasifikasi SVM, dihasilkan akurasi sebesar 61,63%. Dan proses pengujian kamus Bing Liu dan AFINN digabungkan menjadi 2 karena pada masing-masing kamus hanya menghasilkan satu skor sentimen, pengujian menggunakan klasifikasi SVM, dihasilkan akurasi sebesar 41,03%. Dalam hasil pengujian perbandingan pada kamus Lexicon, akurasi tertinggi dihasilkan oleh kamus NRC.

Kemudian hasil perhitungan akurasi dalam proses pengujian penggabungan kamus *Lexicon*, pada penggabungan kamus Barasa Sentiwordnet dan NRC menggunakan klasifikasi SVM dihasilkan akurasi sebesar 62,50%. Proses penggabungan kamus Barasa Sentiwordnet dan Afinn menggunakan klasifikasi SVM dihasilkan akurasi sebesar 46,20%. Proses penggabungan kamus Barasa Sentiwordnet dan Bing Liu menggunakan klasifikasi SVM dihasilkan akurasi sebesar 62,50%. Proses penggabungan kamus NRC dan Afinn menggunakan klasifikasi SVM dihasilkan akurasi sebesar 60,70%. Proses penggabungan kamus NRC dan Bing Liu menggunakan klasifikasi SVM dihasilkan akurasi sebesar 63,03%. Proses penggabungan Barasa SentiwordNet, Bing Liu, NRC, dan AFINN menggunakan klasifikasi SVM dihasilkan akurasi sebesar 63,40%. Kemudian pada proses penggabungan terakhir, yaitu Barasa SentiwordNet, Bing Liu, NRC, AFINN, dan *Lexicon* Heeryon Cho menggunakan klasifikasi SVM dihasilkan akurasi sebesar 64,13%. Dalam hasil pengujian penggabungan pada kamus Lexicon, akurasi tertinggi dihasilkan oleh penggabungan kamus Barasa SentiwordNet, Bing Liu, NRC, AFINN, dan *Lexicon* Heeryon Cho.

4. SIMPULAN

Kesimpulan yang dapat diambil dari hasil penelitian yang telah dilakukan, bahwa hasil perbandingan akurasi antar kamus *Lexicon*, akurasi tertinggi dihasilkan oleh kamus NRC dengan akurasi sebesar 61,63%. Kemudian hasil pengujian akurasi penggabungan antar kamus Barasa Sentiwordnet, Bing Liu, NRC, AFINN dan *Lexicon* Heeryon Cho yang berisi kombinasi kata dari seluruh kamus dihasilkan nilai sebesar 64,43%. Adapun saran yang dapat diberikan berdasarkan penelitian ini adalah, kamus *Lexicon Based* biasanya digunakan untuk sentimen positif dan negatif. Sehingga jika diimplementasikan pada *multiclass*, sulit untuk mengidentifikasi termasuk pada kelas bencana mana tweet laporan bencana gempa tersebut. Saran untuk menaikkan akurasi, dibuat kamus *Lexicon* baru khusus untuk mengidentifikasi bencana alam.

DAFTAR PUSTAKA

- [1] Cho, H., Lee, J.-S., & Kim, S. (2013). *Enhancing Lexicon-Based Review Classification by Merging and Revising Sentiment Dictionaries*. *Proceedings of the Sixth International Joint Conference on Natural Language Processing, October*, 463–470. <http://www.aclweb.org/anthology/I13-1053>
- [2] Gaikwad, G., & Joshi, D. J. (2016). *Multiclass Mood classification on twitter using lexicon dictionary and machine learning algorithms*. *Proceedings of the International Conference on Inventive Computation Technologies, ICICT 2016, 1*, 1–6. <https://doi.org/10.1109/INVENTIVE.2016.7823247>
- [3] Kurniawan, A., Indriati, & Adinugroho, S. (2019). *Analisis Sentimen Opini Film*

Menggunakan Metode Naïve Bayes dan Lexicon Based Features. Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer, 3(9), 8335–8342.

- [4] Mahendrajaya, R., Buntoro, G. A., & Setyawan, M. B. (2019). Analisis Sentimen Pengguna Gopay Menggunakan Metode Lexicon Based Dan Support Vector Machine. *Komputek*, 3(2), 52. <https://doi.org/10.24269/jkt.v3i2.270>
- [5] Rohman, A. N., Utami, E., & Raharjo, S. (2019). **Deteksi Kondisi Emosi pada Media Sosial Menggunakan Pendekatan Leksikon dan Natural Language Processing.** Eksplora Informatika, 9(1), 70–76. <https://doi.org/10.30864/eksplora.v9i1.277>
- [6] Zahra, K., Imran, M., & Ostermann, F. O. (2020). **Automatic identification of eyewitness messages on twitter during disasters.** *Information Processing and Management*, 57(1), 102107. <https://doi.org/10.1016/j.ipm.2019.102107>