

# ANALISIS SENTIMEN PADA TWITTER MENGENAI PASCA BENCANA MENGGUNAKAN METODE NAÏVE BAYES DENGAN FITUR N-GRAM

Imam Fahrur Rozi, S.T., M.T<sup>1</sup>, Annisa Taufika Firdausi, S.T., M.T<sup>2</sup>, Khalimatul Islamiyah<sup>3</sup>

<sup>1,2,3</sup>Program Studi Teknik Informatika, Jurusan Teknologi Informasi, Politeknik Negeri Malang  
<sup>1</sup> imam.rozi@polinema.ac.id, <sup>2</sup> annisa.taufika@polinema.ac.id, <sup>3</sup> khalimatulislamiyah39@gmail.com

## Abstrak

Bencana alam sering terjadi di wilayah Indonesia, pemberian bantuan yang efisien dan sesuai kebutuhan sangat berpengaruh terhadap proses pemulihan pasca bencana alam. Melalui *twitter* masyarakat banyak memberikan respon mengenai bencana alam, akan tetapi respon tersebut belum terklasifikasikan. Oleh karenanya, diperlukan klasifikasi respon masyarakat mengenai bencana alam. Dalam penelitian ini, dilakukan analisis sentimen terhadap *tweet* dengan mengklasifikasikan kedalam kategori positif atau negatif menggunakan algoritma *Naïve Bayes Classifier*. Dari hasil klasifikasi tersebut kita dapat memprioritaskan bantuan dengan mengkategorikan setiap hasil klasifikasi. Dari hasil klasifikasi tersebut positif diartikan bantuan berdasarkan kategori tersebut telah terpenuhi sedangkan negatif berarti bantuan tersebut kurang atau dibutuhkan. Penelitian ini juga akan menggunakan fitur *N-Gram* yaitu *unigram* dan *bigram*. Pada pengujian penelitian ini dilakukan empat kali pengujian. Setiap pengujian, presentase data *training* nya berbeda karena jumlah data *training* juga berpengaruh terhadap peningkatan nilai akurasi. Hasil dari pengujian tersebut diperoleh nilai akurasi untuk *unigram* sebesar 76.67%, 84.44%, 90.00% dan 93.33%. Nilai akurasi untuk *bigram* sebesar 64.17%, 68.89 %, 75.00%, 86.67%. Dari empat pengujian didapatkan hasil akurasi tertinggi pada *unigram* yaitu sebesar 93.33% dan *bigram* sebesar 86.67%. Jadi untuk nilai akurasi *unigram* lebih tinggi daripada *bigram*.

**Kata kunci :** Pasca Bencana, Naïve Bayes Classifier, N-Gram

## 1. Pendahuluan

Di Indonesia akhir-akhir ini sering terjadi bencana alam. Selain wilayahnya yang dilintasi jajaran pegunungan berapi dan terletak diantara 2 samudera besar dunia menjadikan wilayah Indonesia rawan tsunami dan gempa bumi. Seperti yang terjadi pada 28 September 2018, gempa berkekuatan 7,5 SR menghantam pulau Sulawesi. Gempa tersebut menghancurkan sejumlah besar bangunan di daerah tersebut serta memicu tsunami yang menghancurkan sebagian besar kota pesisir Palu [1].

Setiap kelompok masyarakat mempunyai pengetahuan dan cara untuk menghadapi bencana demi kelangsungan hidupnya. Diantaranya yaitu dengan penggunaan media sosial yang saat ini semakin banyak digunakan oleh masyarakat termasuk mengenai bencana alam yang terjadi di Indonesia.

Direktur Pelayanan Informasi Internasional Ditjen Informasi dan Komunikasi Publik (IKP), Selamatta Sembiring mengatakan, *twitter* merupakan salah satu situs jejaring sosial yang paling banyak diakses di Indonesia dan menempati peringkat 5 pengguna *twitter* terbesar di dunia. Pengguna *twitter*, berdasarkan data PT Bakrie Telecom, memiliki 19,5 juta pengguna di Indonesia dari total 500 juta pengguna global. Melalui *twitter*

pengguna dapat melakukan *tweet* dengan topik yang beragam seputar opini mereka atau tentang hal-hal darurat yang terjadi seperti bencana alam.

*Tweet* dari pengguna tentang bencana alam dapat menjadi informasi untuk menentukan bantuan yang sesuai dengan kebutuhan dan mempercepat pemulihan pasca bencana. Meskipun pemerintah dan organisasi tanggap bencana telah bekerja sama, sentimen dari orang-orang yang terkena dampak bencana sangat menentukan keberhasilan tanggap bencana dan proses pemulihan. Dalam penelitian ini, dilakukan analisis sentimen untuk membantu dan memahami kebutuhan yang tepat setelah bencana sehingga informasi yang dihasilkan dapat membantu banyak pihak untuk mendukung suatu keputusan atau pilihan seperti dengan mengkategorikan berbagai kebutuhan masyarakat seperti tempat tinggal, medis, makanan, air dan listrik. Salah satu teknik pembelajaran untuk analisis sentimen adalah *Naïve Bayes Classifier*. Metode *Naïve Bayes Classifier* dianggap sebagai metode yang berpotensi baik untuk melakukan klasifikasi data daripada metode klasifikasi lainnya dalam hal akurasi dan komputasi [2].

Penelitian terkait dengan jurnal yang berjudul *Perbandingan Klasifikasi Tugas Akhir Mahasiswa Jurusan Teknik Informatika Menggunakan Metode Naïve Bayes Classifier Dan K-Nearest Neighbor*

mendapatkan hasil bahwa metode *Naive Bayes Classifier* menghasilkan nilai akurasi lebih baik, yaitu sebesar 87% dibandingkan dengan pengujian pada metode *K-Nearest Neighbor* yang menghasilkan nilai akurasi 84% [3]. Berdasarkan penjelasan tersebut, penelitian tentang analisis sentimen pada *Twitter* untuk tanggap bencana dan pemulihan ini menggunakan algoritma *Naive Bayes Classifier* untuk mengklasifikasi *tweet* positif dan negatif dengan menerapkan penggunaan fitur *N-gram*. Sebagaimana pada penelitian sebelumnya tentang penggunaan *n-gram* pada analisa sentimen pemilihan kepala daerah jakarta menggunakan algoritma *naive bayes*, hasil dari rata-rata nilai *accuracy* paling besar terdapat pada penggunaan *bigram* yaitu 0,823, ini menunjukkan bahwa dengan menggunakan *bigram* ketepatan akurasi dari sistem lebih baik dibandingkan menggunakan *unigram* atau *trigram*, nilai *precision* tertinggi juga terdapat pada penggunaan *bigram* dengan 0,76 [4]. Oleh karena itu, penelitian ini akan melakukan Analisis Sentimen Pada *Twitter* Mengenai Pasca Bencana Menggunakan Metode *Naive Bayes* Dengan Fitur *N-Gram*.

## 2. Tinjauan Pustaka

### 2.1 Text Mining

Penambangan teks (bahasa Inggris: *text mining*) adalah proses ekstraksi pola berupa informasi dan pengetahuan yang berguna dari sejumlah besar sumber data teks, seperti dokumen Word, PDF, kutipan teks, dll. Jenis masukan untuk penambangan teks ini disebut data tak terstruktur dan merupakan pembeda utama dengan penambangan data yang menggunakan data terstruktur atau basis data sebagai masukan. Penambangan teks dapat dianggap sebagai proses dua tahap yang diawali dengan penerapan struktur terhadap sumber data teks dan dilanjutkan dengan ekstraksi informasi dan pengetahuan yang relevandari data teks terstruktur ini dengan menggunakan teknik dan alat yang sama dengan penambangan data. Proses yang umum dilakukan oleh penambangan teks di antaranya adalah perangkuman otomatis, kategorisasi dokumen, penggugusan teks, dan lain-lain [5].

### 2.2 Sentiment Analysis

Sentiment analysis atau analisis sentimen dalam Bahasa Indonesia adalah sebuah teknik atau cara yang digunakan untuk mengidentifikasi bagaimana sebuah sentimen diekspresikan menggunakan teks dan bagaimana sentimen tersebut bisa dikategorikan sebagai sentimen positif maupun sentimen negatif [6]. Pendapat yang hampir sama juga mengatakan di mana analisis sentimen digunakan untuk memahami komentar yang diciptakan oleh pengguna (*internet*) dan menjelaskan bagaimana sebuah produk maupun brand diterima oleh mereka [7]. Sedangkan pada jurnal yang berjudul *Combining Classification and Clustering for Tweet*

Sentiment Analysis, analisis sentimen adalah proses yang digunakan untuk menentukan opini, emosi dan sikap yang dicerminkan melalui teks, dan biasanya diklasifikasikan menjadi opini negatif dan positif [8]. Dari ketiga pendapat diatas, bisa diambil kesimpulan bahwa analisis sentimen adalah sebuah proses untuk menentukan sentimen atau opini dari seseorang yang diwujudkan dalam bentuk teks dan bisa dikategorikan sebagai sentimen positif atau negatif. Sebagaimana yang sudah dituliskan sebelumnya bahwa pengguna internet banyak menuliskan pengalaman, opini dan segala hal yang menjadi perhatian mereka. Tulisan tentang apa yang mereka rasakan ini berupa perasaan positif, netral maupun negatif yang bisa diungkapkan dengan cara yang cukup kompleks [9].

### 2.3 Algoritma Naive Bayes Classifier

Metode NBC menempuh dua tahap dalam proses klasifikasi teks, yaitu tahap pelatihan dan tahap klasifikasi. Pada tahap pelatihan dilakukan proses analisis terhadap sampel dokumen berupa pemilihan vocabulary, yaitu kata yang mungkin muncul dalam koleksi dokumen sampel yang sedapat mungkin dapat menjadi representasi dokumen. Selanjutnya adalah penentuan probabilitas prior bagi tiap kategori berdasarkan sampel dokumen. Pada tahap klasifikasi ditentukan nilai kategori dari suatu dokumen berdasarkan term yang muncul dalam dokumen yang diklasifikasi. Lebih konkritnya jika diasumsikan dimiliki koleksi dokumen  $D = \{d_i \mid i=1,2,\dots,|D|\} = \{d_1,d_2,\dots,d_{|D|}\}$  dan koleksi kategori  $V = \{v_j \mid j=1,2,\dots,|V|\} = \{v_1,v_2,\dots,v_{|V|}\}$ . Klasifikasi NBC dilakukan dengan cara mencari probabilitas  $P(V=v_j \mid D=d_i)$ , yaitu probabilitas category  $v_j$  jika diketahui dokumen  $d_i$ . Dokumen di dipandang sebagai tuple dari kata-kata dalam dokumen, yaitu  $\langle a_1, a_2, \dots, a_n \rangle$ , yang frekuensi kemunculannya diasumsikan sebagai variable *random* dengan distribusi probabilitas *Bernoulli* (*McCallum and Nigam, 1998*). Selanjutnya klasifikasi dokumen adalah mencari nilai maksimum dari :

$$V_{MAP} = \arg \max_{v_j \in V} P(v_j \mid (a_1, a_2, \dots, a_n)) \quad (1)$$

Teorema *Bayes* menyatakan tentang probabilitas bersyarat menyatakan:

$$P(B|A) = \frac{P(A|B)P(B)}{P(A)} \quad (2)$$

Dengan menerapkan teorema Bayes persamaan (1) dapat ditulis:

$$V_{MAP} = \arg \max_{v_j \in V} \frac{P(a_1, a_2, \dots, a_n \mid v_j)P(v_j)}{P(a_1, a_2, \dots, a_n)} \quad (3)$$

Karena nilai  $P(a_1, a_2, \dots, a_n)$  untuk semua  $v_j$  besarnya sama maka nilainya dapat diabaikan, sehingga persamaan (3) menjadi :

$$V_{MAP} = \arg \max_{v_j \in V} P(a_1, a_2, \dots, a_n | v_j) P(v_j) \quad (4)$$

Dengan mengasumsikan bahwa setiap kata dalam  $\langle a_1, a_2, \dots, a_n \rangle$  adalah independent, maka  $P(a_1, a_2, \dots, a_n)$  dalam persamaan (4) dapat ditulis sebagai :

$$P(a_1, a_2, \dots, a_n | v_j) = \prod_i P(a_i | v_j) \quad (5)$$

Sehingga persamaan (4) dapat ditulis :

$$V_{MAP} = \arg \max_{v_j \in V} P(v_j) \prod_i P(a_i | v_j) \quad (6)$$

Nilai  $P(v_j)$  ditentukan pada saat pelatihan, yang nilainya didekati dengan :

$$P(v_j) = \frac{|doc_j|}{|Contoh|} \quad (7)$$

Dimana  $|doc_j|$  adalah banyaknya dokumen yang memiliki kategori  $j$  dalam pelatihan, sedangkan  $|Contoh|$  banyaknya dokumen dalam contoh yang digunakan untuk pelatihan.

Untuk nilai  $P(w_k | v_j)$ , yaitu probabilitas kata  $w_k$  dalam kategori  $j$  ditentukan dengan:

$$P(w_k | v_j) = \frac{n_k + 1}{n + |vocabulary|} \quad (8)$$

Dimana  $n_k$  adalah frekuensi munculnya kata  $w_k$  dalam dokumen yang ber kategori  $v_j$ , sedangkan nilai  $n$  adalah banyaknya seluruh kata dalam dokumen berkategori  $v_j$ , dan  $|vocabulary|$  adalah banyaknya kata dalam contoh pelatihan [10].

Pengujian pada performa algoritma Naive Bayes Classifier dilakukan dengan menguji tingkat akurasi, presisi dan recall.

Dalam melakukan penghitungan tingkat akurasi algoritma *Naive Bayes Classifier* dengan rumus sebagai berikut:

$$Akurasi = \frac{\sum \text{data benar}}{n \text{ dokumen}} \times 100 \% \quad (9)$$

Rumus untuk melakukan penghitungan tingkat presisi sebagai berikut:

$$Presisi = \frac{\sum \text{data positif atau negatif}}{n \text{ dokumen positif atau negatif}} \times 100 \% \quad (10)$$

Rumus untuk melakukan penghitungan recall sebagai berikut:

$$recall = \frac{\sum \text{doc relevan dan terambil}}{\sum \text{seluruh dokumen relevan}} \times 100\% \quad (11)$$

Proses perhitungan prioritas bantuan dilakukan untuk menyamakan data dan melihat data mana yang lebih tinggi dalam suatu dataset sehingga dapat ditampilkan prioritas dari bantuan yang dibutuhkan. Perhitungan prioritas bantuan perkategori dilakukan dengan rumus sebagai berikut:

$$Jumlah = \frac{\sum \text{seluruh dataset}}{\sum \text{dataset perkategori}} \quad (12)$$

Rumus untuk menghitung rata-rata dari dataset perkategori :

$$JumlahKategori = \frac{\sum \text{dataset perkategori}}{\sum \text{dataset positif atau negatif}} \quad (13)$$

Selanjutnya menghitung keseluruhan dari hasil rata-rata perhitungan dengan rumus:

$$Hasil = Jumlah \times JumlahKategori \quad (14)$$

### 2.4 Fitur N-Gram

Bahasa tidak terbentuk dari kata-kata individu, tetapi terdiri dari urutan kata individu dan frase 2, 3 atau lebih kata yang lebih dikenal *n-gram* dengan masing-masing kata tersebut mengandung informasi tersendiri, contoh penerapan *n-gram* khususnya *trigram* pada kalimat “The cat sat on the mat” menjadi “the cat sat”, “cat sat on”, “sat on the” dan “on the mat” apabila terdapat sebuah *punctuation* seperti koma, semi kolon, dan sebagainya maka pada proses *n-gram* tidak melewatinya melainkan membuat *n-gram* baru dengan kata setelah karakter tersebut misalnya pada kalimat “Three blind mice, see how they run” untuk *trigram* menjadi “three blind mice”, “see how they” dan “how they run” [11]

Pada penelitian ini menerapkan *n-gram* dengan pemecahan kata pada kalimat ulasan meliputi *unigram* adalah pemecahan kata pada kalimat ulasan dengan  $n=1$  atau *term* tunggal dan *bigram* adalah pemecahan *n-kata* pada kalimat ulasan dengan  $n=2$ . Berikut ilustrasi penerapan *n-gram* pada kalimat “aku suka banget produk cleanser ini.” [12]:

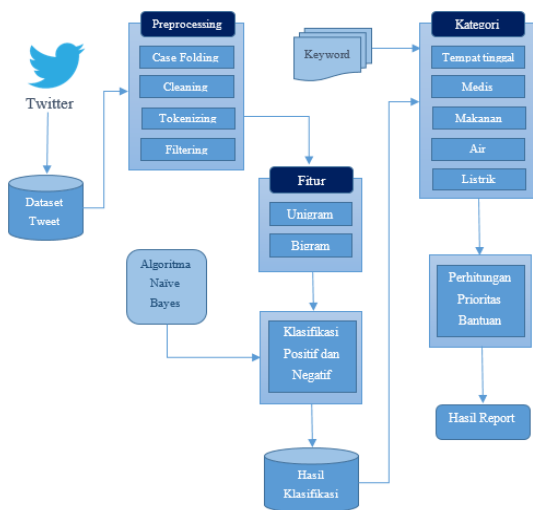
*Unigram*: ‘aku’, ‘suka’, ‘banget’, ‘produk’, ‘cleanser’, ‘ini’.

*Bigram*: ‘aku suka’, ‘suka banget’, ‘banget produk’, ‘produk cleanser’, ‘cleanser ini’.

### 3. Metode Penelitian

Dalam penelitian ini, dilakukan pengolahan data terhadap data *tweet* pengguna *twitter* yang diambil dari *Twitter API*. Data tersebut kemudian masuk ke tahap *preprocessing* untuk menghindari data yang kurang sempurna, gangguan pada data, dan data-data yang tidak konsisten sehingga keluaran dari klasifikasi memiliki keakurasian yang tinggi. Tahapan dalam *preprocessing* yaitu :

1. *Case folding*  
*Case folding* dengan mengubah semua huruf menjadi huruf kecil.
2. *Cleaning*  
*Cleaning* adalah tahap dimana karakter selain huruf dihilangkan dan menghapus URL, *Username* dan *Mention*.
3. *Tokenizing*  
*Tokenizing* adalah tahap pemotongan *string input* berdasarkan tiap kata yang menyusunnya. Hasil dari proses ini adalah berupa kumpulan kata-kata tanpa tandabaca, karakter, dan angka
4. *Filtering*  
Proses *filtering* ini adalah untuk menghapus setiap kata-kata yang tidak memiliki arti atau kata-kata yang sering muncul pada data komentar.



Gambar 1. Metode Pengolahan Data

Pada gambar 1 dijelaskan metode pengolahan data mulai dari proses *crawling* menggunakan *Twitter* API, setelah itu masuk ke tahap *preprocessing*, lalu data hasil *preprocessing* tersebut masuk tahap klasifikasi positif atau negatif dengan fitur *unigram* dan *bigram* menggunakan algoritma *Naive Bayes* kemudian disimpan ke dalam database lalu dikategorikan untuk menentukan objek yang telah di klasifikasi dengan menggunakan beberapa kategori dan *keyword* seperti berikut :

TABEL I. KATEGORI DAN KEYWORD

No	Kategori	Keyword
	Tempat tinggal	Tempat tinggal, hunian, rumah, pengungsian, bangun, pemukiman
2	Medis	Medis, obat, sakit, penyakit, kesehatan, dokter
3	Makanan	Makan, bahan pokok, lapar, pangan
4	Air	Air, minum, haus
5	Listrik	Listrik, padam

Kategori dan *keyword* pada tabel 1 didapatkan dari hasil observasi dan jurnal sebelumnya yang melakukan penelitian mengenai bencana alam. Setelah dilakukan pengkategorian selanjutnya menghitung prioritas bantuan berdasarkan hasil testing dan kategori kemudian sistem akan menampilkan hasil *report*.

#### 4. Pengujian Sistem

##### 4.1 Pengujian Akurasi Algoritma (*Accuracy, Precision, Recall*)

Pada pengujian akurasi algoritma dilakukan pengujian terhadap hasil klasifikasi data testing. Dalam mengetahui keberhasilan algoritma dalam proses klasifikasi maka akan dibandingkan hasil klasifikasi yang dilakukan oleh sistem dengan hasil

klasifikasi pelabelan manual hasil kuisioner sebanyak 15 orang responden. Perbandingan tersebut akan dihitung tingkat kebenarannya menggunakan *accuracy, precision* dan *recall*. Semakin tinggi nilai *accuracy, precision* dan *recall* sebuah algoritma yang digunakan maka semakin menunjukkan bahwa algoritma tersebut bekerja dengan baik untuk proses klasifikasi.

Pengujian dilakukan dengan memilih data training dan data testing secara acak dari 300 data yang akan digunakan. Komposisi pembagian data training dan data testing dapat dilihat pada tabel 5.9.

TABEL II. PRESENTASE DATA

Presentase Data		Jumlah Data	
<i>Training</i>	<i>Testing</i>	<i>Training</i>	<i>Testing</i>
60%	40%	180	120
70%	30%	210	90
80%	20%	240	60
90%	10%	270	30

Pengujian selanjutnya dilakukan dengan memilih secara acak data training dan testing dari 300 data tersebut. Data training dipilih sebanyak 60% dan 40% digunakan untuk data testing.

TABEL III. PENGUJIAN DATA TRAINING 60% DAN DATA TESTING 40%

Keterangan	Pengujian				
	<i>Accur</i> <i>acy</i>	<i>Precisi</i> <i>on+</i>	<i>Precisi</i> <i>ion-</i>	<i>Reca</i> <i>ll+</i>	<i>Reca</i> <i>ll-</i>
<i>Unigra</i> <i>m</i>	76.67 %	78.65 %	70.97 %	88.6 1%	53.6 6%
<i>Bigram</i>	64.17 %	82.19 %	62.96 %	75.9 5%	41.4 6%

Melalui pengujian pada tabel 5.10 didapatkan bahwa nilai *accuracy* dari *unigram* sebesar 76.67% dan *bigram* sebesar 64.17%. Nilai *precision* positif memiliki nilai 78.65% untuk *unigram* dan 82.19% untuk *bigram*. *Precision* negatif memiliki nilai 70.97% untuk *unigram* dan 62.96% untuk *bigram*. *Recall* positif memiliki nilai 88.61% untuk *unigram* dan 75.95% untuk *bigram*. *Recall* negatif memiliki nilai 53.66% untuk *unigram* dan 41.46% untuk *bigram*. Hal tersebut menunjukkan bahwa untuk pengujian dengan data *training* 60% dan *testing* 40% nilai *accuracy, precision* negatif, *recall* positif dan *recall* negatif pada *unigram* lebih baik daripada *bigram*. Sedangkan untuk *precision* positif *bigram* lebih baik daripada *unigram*.

TABEL IV. PENGUJIAN DATA TRAINING 70% DAN DATA TESTING 30%

Data Training 70% : Data Testing 30%					
Keterangan	Pengujian				
	Accuracy	Precision+	Precision-	Recall+	Recall-
Unigram	84.44 %	86.36 %	79.17 %	91.9 4%	67.8 6%
Bigram	68.89 %	80.95 %	78.57 %	82.2 6%	39.2 9%

Dilakukan pengujian kedua pada tabel 5.11 dengan perbandingan data training sebesar 70% dan data testing sebesar 30%. Nilai accuracy, precision positif, precision negatif, recall positif dan recall negatif didapatkan bahwa keseluruhan nilai untuk unigram cenderung lebih tinggi daripada bigram.

TABEL V. PENGUJIAN DATA TRAINING 80% DAN DATA TESTING 20%

Data Training 80% : Data Testing 20%					
Keterangan	Pengujian				
	Accuracy	Precision+	Precision-	Recall+	Recall-
Unigram	90.00 %	93.02 %	82.35 %	93.0 2%	82.3 5%
Bigram	75.00 %	80.43 %	100.00 %	86.0 5%	47.0 6%

Pengujian ketiga pada tabel 5.12 dilakukan dengan menggunakan perbandingan data training sebesar 80% dan 20%. Nilai accuracy, precision positif, precision negatif, recall positif dan recall negatif mengalami peningkatan dari sebelumnya dan didapatkan bahwa unigram nilainya lebih tinggi daripada bigram.

TABEL VI. PENGUJIAN DATA TRAINING 90% DAN DATA TESTING 10%

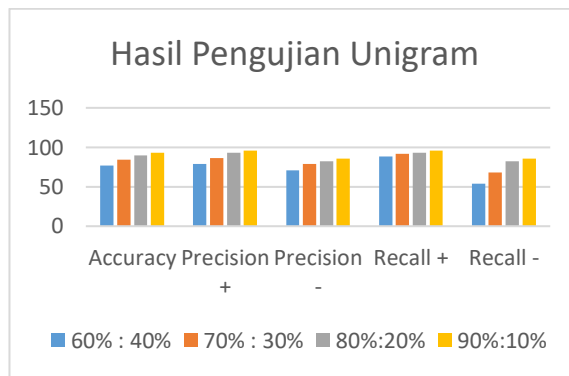
Data Training 90% : Data Testing 10%					
Keterangan	Pengujian				
	Accuracy	Precision+	Precision-	Recall+	Recall-
Unigram	93.33 %	95.65 %	85.71 %	95.6 5%	85.7 1%
Bigram	86.67 %	91.30 %	100.00 %	91.3 0%	71.4 3%

Pengujian keempat pada tabel 5.13 dilakukan dengan menggunakan perbandingan data training sebesar 90% dan 10%. Nilai accuracy, precision positif, precision negatif, recall positif dan recall negatif juga meningkat dari pengujian sebelumnya dan unigram tetap mendapatkan nilai lebih tinggi daripada bigram meskipun sama-sama mengalami peningkatan.

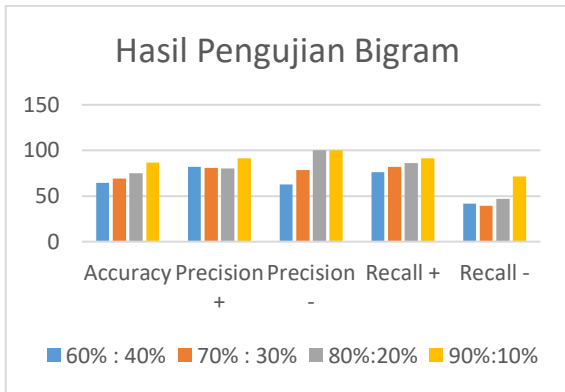
Dari hasil keempat pengujian diatas, nilai accuracy algoritma Naïve Bayes Classifier untuk unigram secara berturut-urut didapatkan sebesar 76.67%, 84.44%, 90.00% dan 93.33%. Nilai akurasi terendah adalah 76.67% dan tertinggi adalah 93.33%. Nilai accuracy untuk bigram secara berturut-urut didapatkan hasil sebesar 64.17%, 68.89 %, 75.00%, 86.67%. Nilai akurasi terendah adalah 64.17% dan tertinggi adalah 86.67%.

Dapat disimpulkan bahwa penggunaan fitur unigram ternyata akurasi lebih tinggi daripada bigram, hal tersebut dikarenakan kata tunggal dalam bentuk unigram ternyata lebih banyak dipakai pada suatu kalimat dan umum penggunaannya, untuk bigram terdapat kata-kata khusus yang memang jarang digunakan pada suatu kalimat atau tweet. Contohnya terdapat tweet “ratusan pengungsi kalianda butuh makan minum” apabila dilakukan perhitungan tf maka kata “butuh” lebih banyak digunakan daripada kata “butuh makan”. Oleh karenanya hasil akurasi unigram lebih tinggi daripada bigram.

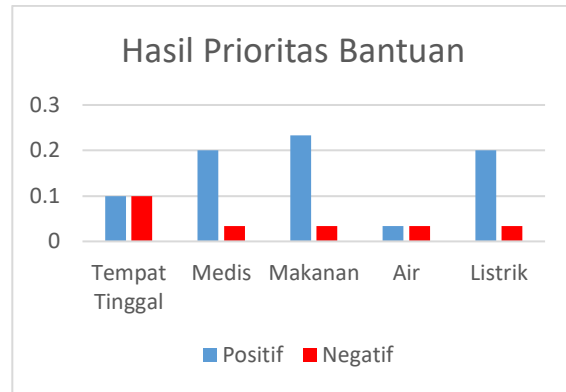
Selanjutnya, setiap terjadi penambahan data training, maka nilai dari accuracy, precision dan recall juga mengalami peningkatan. Hal ini dikarenakan algoritma naïve bayes merupakan metode supervised learning yang sangat bergantung pada data training, kemungkinan akurasi dapat ditingkatkan lagi dengan menambahkan data training yang banyak. Seperti hasil dari penelitian ini pada gambar 5.33 dan 5.34 setiap terjadi penambahan data training maka akurasi cenderung mengalami peningkatan.



Gambar 2 Grafik hasil pengujian unigram



Gambar 3 Grafik hasil pengujian bigram

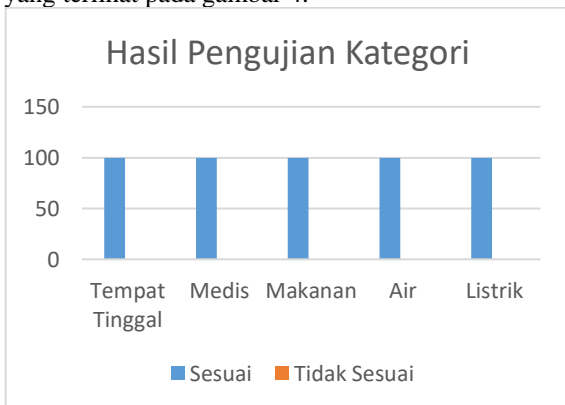


Gambar 5. Grafik hasil perhitungan prioritas

#### 4.2 Pengujian Akurasi Kategori

Pengujian akurasi kategori bertujuan untuk menguji akurasi keberhasilan suatu *tweet* masuk kedalam kategori yang sesuai berdasarkan *keyword* yang telah ditentukan sebelumnya. Pengujian dilakukan dengan menggunakan sampel 10% dari dataset yaitu sebanyak 30 *tweet* yang telah terklasifikasi.

Dari 5 kategori tersebut semuanya memiliki akurasi yang tinggi sebesar 100% hal tersebut dikarenakan *keyword* yang digunakan semuanya dapat terdeteksi pada suatu *tweet* dan dapat terkategori sesuai dengan yang diinginkan seperti yang terlihat pada gambar 4.



Gambar 4 Grafik hasil pengujian akurasi kategori

Selanjutnya untuk hasil perhitungan prioritas bantuan dari hasil klasifikasi dapat dilihat pada tabel 5.19.

TABEL VII. PERHITUNGAN PRIORITAS BANTUAN

No	Kategori	Positif	Negatif
1	Tempat Tinggal	0.1	0.1
2	Medis	0.2	0.333333
3	Makanan	0.233333	0.333333
4	Air	0.333333	0.333333
5	Listrik	0.2	0.333333

Pada hasil perhitungan prioritas bantuan terdapat diagram positif dan negatif pada setiap kategori. Positif diartikan bantuan berdasarkan kategori tersebut telah terpenuhi sedangkan negatif berarti bantuan tersebut kurang atau dibutuhkan. Berdasarkan gambar 5.35 dapat diketahui jika bantuan makanan sudah sangat terpenuhi dan untuk bantuan tempat tinggal posisinya sejajar antara terpenuhi dan kurang, akan tetapi dari kelima kategori tersebut kategori yang paling dibutuhkan adalah tempat tinggal.

#### 5. Kesimpulan Dan Saran

##### 5.1 Kesimpulan

Berdasarkan hasil penelitian dan pengujian yang telah dilakukan dapat ditarik kesimpulan sebagai berikut:

1. Algoritma *Naïve Bayes Classifier* dapat digunakan untuk mengklasifikasikan *tweet* kedalam positif atau negatif terutama *tweet* mengenai pasca bencana.
2. Pengujian akurasi algoritma yang dilakukan dengan pemberian label manual dari 15 responden, didapatkan hasil dari *unigram* dan *bigram* memiliki perbedaan yang cukup signifikan. Dari empat pengujian tersebut didapatkan hasil akurasi tertinggi pada *unigram* yaitu sebesar 93.33% dan *bigram* sebesar 86.67%. Nilai akurasi *unigram* cenderung lebih tinggi daripada *bigram*, hal tersebut dikarenakan kata tunggal dalam bentuk *unigram* ternyata lebih banyak dipakai pada suatu kalimat dan umum penggunaannya, untuk *bigram* terdapat kata-kata khusus yang memang jarang digunakan pada suatu kalimat atau *tweet*. Jumlah data *training* yang digunakan juga berpengaruh dengan peningkatan akurasi terhadap hasil klasifikasi menggunakan algoritma *Naïve Bayes Classifier*.
3. Pada pengujian akurasi kategori didapatkan hasil akurasi yang tinggi yaitu sebesar 100% hal tersebut dikarenakan *keyword* yang digunakan semuanya dapat terdeteksi pada

suatu *tweet* dan dapat terkategori sesuai dengan yang diinginkan.

## 5.2 Saran

Saran yang dapat diberikan dari hasil penelitian untuk pengembangan sistem ini kedepan sebagai berikut :

1. Sistem dapat melakukan *crawling* data secara *real time* menggunakan *Twitter* API.
2. Dapat dikembangkan dengan penambahan fitur yang lain seperti *POS-Tagging*.

## Daftar Pustaka

- Alejandro Quiroz Flores. 2018. "Bencana Alam Bisa Runtuhkan Demokrasi Indonesia". <https://www.matamatapolitik.com/bencana-alam-bisa-runtuhkan-demokrasi-indonesia/>.
- Ting, S. L., Ip, W. H., & Tsang, A. H. 2011. "Is Naïve Bayes a Good Classifier for Document Classification?". *International Journal of Software Engineering and Its Applications*, 5(3), 3746.
- Yusra, Dhita Olivita, Yelfi Vitriani. "Perbandingan Klasifikasi Tugas Akhir Mahasiswa Jurusan Teknik Informatika Menggunakan Metode Naïve Bayes Classifier dan K-Nearest Neighbor". *Jurnal Sains, Teknologi dan Industri*, Vol. 14, No. 1, Desember 2016, pp. 79 – 85.
- Wahyu Candra Indhiarta. 2017. "Penggunaan N-Gram Pada Analisa Sentimen Pemilihan Kepala Daerah Jakarta Menggunakan Algoritma Naïve Bayes". [Fakultas Komunikasi Dan Informatika Universitas Muhammadiyah Surakarta](#).
- Denny Nathaniel Chandra, Gede Indrawan, I Nyoman Sukajaya "Klasifikasi Berita Lokal Radar Malang Menggunakan Metode Naïve Bayes Dengan Fitur N-Gram". *Jurnal Ilmiah Teknologi dan Informasia ASIA (JITIKA)* Vol.10, No.1, Februari 2016.
- [6] Tetsuya Nasukawa, Jeonghee Yi. 2003. "Sentiment Analysis Capturing favorability using Natural Language Processing".
- [7] Irena Pletikosa Cvijikj, Florian Michahelles . 2011. "Understanding Social Media Marketing: A Case Study on Topics, Categories and Sentiment on a Facebook Brand Page".
- [8] Luiz F. S. Coletta, N'adia F. F. da Silva, Eduardo R. Hruschka, Estevam R. Hruschka Jr. 2014. "Combining Classification and Clustering for Tweet Sentiment Analysis".
- [9] Nurrun Muchammad Shiddieqy Hadna, Paulus Insap Santosa, Wing Wahyu Winarno . "Studi Literatur Tentang Perbandingan Metode Untuk Proses Analisis Sentimen di Twitter". Seminar Nasional Teknologi Informasi dan Komunikasi 2016 (SENTIKA 2016) .
- [10] Amir Hamza. 2012 "Klasifikasi Teks Dengan Naïve Bayes Classifier (NBC) Untuk Pengelompokan Teks Berita Dan Abstract Akademis" Prosiding Seminar Nasional Aplikasi Sains & Teknologi (SNAST) Periode III .
- [11] Le Quan Ha , E. I. Sicilia-Garcia , Ji Ming and F. J. Smith. 2003. "Extension of Zipf's Law to Word and Character N-grams for English and Chinese". *Journal of Computational Linguistics and Chinese Language Processing*.
- [12] Annisya Aprilia Prasanti, M. Ali Fauzi, M. Tanzil Furqon. 2018. "Klasifikasi Teks Pengaduan Pada Sambat Online Menggunakan Metode N-Gram dan Neighbor Weighted K-Nearest Neighbor (NW-KNN)". *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*.