

## PEMBENTUKAN DAFTAR *STOPWORD* MENGGUNAKAN *TERM BASED RANDOM SAMPLING* PADA ANALISIS SENTIMEN DENGAN METODE *NAÏVE BAYES* (STUDI KASUS: KULIAH DARING DI MASA PANDEMI)

Raditya Rinandyaswara<sup>\*1</sup>, Yuita Arum Sari<sup>2</sup>, Muhammad Tanzil Furqon<sup>3</sup>

<sup>1,2,3</sup>Universitas Brawijaya, Malang

Email: <sup>1</sup>radityarin@gmail.com, <sup>2</sup>yuita@ub.ac.id, <sup>3</sup>m.tanzil.furqon@ub.ac.id

\*Penulis Korespondensi

(Naskah masuk: 15 Februari 2021, diterima untuk diterbitkan: 15 Agustus 2022)

### Abstrak

*Stopword Removal* merupakan bagian dari tahapan *preprocessing* teks yang bertujuan untuk menghapus kata yang tidak relevan didalam suatu kalimat berdasarkan daftar *stopword*. Daftar *stopword* yang biasa digunakan berbentuk *digital library* yang daftarnya sudah tersedia sebelumnya, namun tidak semua kata-kata yang terdapat didalam *digital library* merupakan kata yang tidak relevan dalam suatu data tertentu. Penelitian ini menggunakan daftar *stopword* yang dibentuk dengan algoritme *Term Based Random Sampling*. Dalam *Term Based Random Sampling* terdapat 3 parameter yaitu  $Y$  untuk jumlah perulangan pengambilan kata *random*,  $X$  untuk jumlah pengambilan bobot terendah dalam perulangan  $Y$ , dan  $L$  sebagai persentase jumlah *stopword* yang ingin digunakan. Sehingga penelitian ini ditujukan untuk mencari kombinasi terbaik dari 3 parameter tersebut serta membandingkan *stopword Term Based Random Sampling* dengan *stopword* Tala dan tanpa proses *stopword removal* dalam analisis sentimen *tweet* mengenai kuliah daring dengan menggunakan metode *Naïve Bayes*. Hasil evaluasi dengan *stopword Term Based Random Sampling* mendapatkan akurasi tertinggi dengan  $X, Y, L$  sebesar 10, 10, 40 dengan *macroaverage accuracy* sebesar 0,758, *macroaverage precision* sebesar 0,658, *macroaverage recall* sebesar 0,636, dan *macroaverage f-measure* sebesar 0,647. Berdasarkan hasil pengujian disimpulkan bahwa semakin besar  $X, Y, L$  maka semakin tinggi kemungkinannya untuk hasil evaluasi turun. Hasil pengujian membuktikan bahwa *Term Based Random Sampling* berhasil mendapatkan akurasi lebih tinggi dibandingkan dengan *stopword* Tala maupun tanpa menggunakan proses *stopword removal*.

**Kata kunci:** *sentimen analisis, kuliah daring, Naïve Bayes, Term Based Random Sampling, stopword*

## FORMING A *STOPWORD* LIST USING *TERM BASED RANDOM SAMPLING* ON THE SENTIMENT ANALYSIS USING THE *NAÏVE BAYES* METHOD (CASE STUDY: ONLINE LECTURES DURING THE PANDEMIC)

### Abstract

*Stopword Removal* is part of the text *preprocessing* stage which aims to remove irrelevant words in a sentence based on the *stopword* list. The *stopword* list that is commonly used is in the form of a *digital library* whose list is already available, but not all words contained in the *digital library* are irrelevant words in certain data. This study uses a *stopword* list formed by the *Term Based Random Sampling* algorithm. In *Term Based Random Sampling*, there are 3 parameters, namely  $Y$  for the number of *random word* retrieval repetitions,  $X$  for the lowest number of weights in  $Y$  repetitions, and  $L$  as the percentage of the number of *stopwords* you want to use. So this research is aimed at finding the best combination of these 3 parameters and comparing the *Term Based Random Sampling stopword* with the *stopword* tuning and without the *stopword removal* process in the analysis of *tweet* sentiment regarding online lectures using the *Naïve Bayes* method. The results of the evaluation with the *Term Based Random Sampling stopword* get the highest accuracy with  $X, Y, L$  of 10, 10, 40 with a *macroaverage accuracy* of 0.758, a *macroaverage precision* of 0.658, a *macroaverage recall* of 0.636, and a *macroaverage f-measure* of 0.647. Based on the test results, it is concluded that the greater the  $X, Y, L$ , the higher the probability that the evaluation results will decrease. The test results prove that *Term Based Random Sampling* is successful in obtaining higher accuracy than *stopword* tuning or without using the *stopword removal* process.

**Keywords:** *sentiment analysis, online lectures, Naïve Bayes, Term Based Random Sampling, Stopword*

## 1. PENDAHULUAN

Pada akhir 2019 lalu, seluruh dunia diberikan kabar buruk terkait dengan adanya wabah yang diakibatkan oleh virus corona yang berawal dari kota Wuhan, China. Penyakit yang disebut sebagai (COVID-19) ini adalah penyakit yang menyerang sistem pernapasan virus manusia. Menurut data pemerintah China, penduduk Hubei menjadi kasus pertama Covid-19 pada 17 November 2019 (Arnani, 2020). Setelah kasus pertama Covid-19 di dunia itu terjadi peningkatan pasien tiap bulannya. Hingga saat ini Indonesia sudah melewati angka 190 ribu kasus Covid-19 yang sudah terkonfirmasi yang dihitung dari sejak pasien pertama. Dengan adanya pandemi Covid-19 ini, pemerintah Indonesia mengadakan sistem *New Normal* dengan tujuan untuk mempercepat penanganan Covid-19. Dalam penerapannya banyak kegiatan-kegiatan masyarakat yang beralih dari secara luring menjadi daring. Salah satu contohnya adalah perkuliahan.

Kebijakan kuliah daring ini ramai menjadi perbincangan seluruh masyarakat terutama mahasiswa di Indonesia. Media sosial seperti *Twitter* menjadi salah satu sarana mahasiswa menuliskan pendapatnya terkait kuliah daring ini. Ada yang menganggap kebijakan ini secara positif, salah satu alasannya yaitu mengingat meningkatnya kasus Covid-19 setiap harinya. Namun di sisi lain, ada yang menganggap kebijakan ini secara negatif, salah satu alasannya yaitu, ketidakpahaman terhadap materi kuliah yang diajarkan melalui daring. Selain itu, ada juga yang menganggap kebijakan ini secara netral, yaitu mereka yang melihat dari kedua sisi baik negatif maupun positif. Melihat banyaknya masyarakat menanggapi kebijakan ini, akan sulit jika proses melihat tanggapan masyarakat satu per satu. Sehingga sistem penambangan teks atau *Text Mining* diperlukan untuk menganalisa bagaimana tanggapan masyarakat serta untuk memudahkan proses analisa data.

Text mining merupakan proses pengambilan informasi dari sebuah teks melalui peramalan pola dan kecenderungan dengan menggunakan ilmu statistik (Zuli, et al., 2020). Text mining dapat digunakan untuk proses klasifikasi sebuah teks yang salah satu contohnya adalah analisis sentimen.

Analisis sentimen merupakan sebuah metode yang digunakan untuk mengekstrak data opini, memahami serta mengolah tekstual data secara otomatis untuk melihat sentimen yang terkandung dalam sebuah opini (Sari, 2019). Dengan proses analisis sentimen ini kita dapat mengetahui bagaimana pendapat orang apakah cenderung positif, negatif ataupun netral.

Sudah ada penelitian terdahulu mengenai analisis sentimen dari *Twitter*, salah satunya adalah oleh (Antinasari, et al., 2017) yang menggunakan metode *Naïve Bayes*. Data yang digunakan *tweet* terkait dengan opini film. Penelitian terdahulu ini juga menambahkan *Levenshtein Distance* sebagai

metode yang digunakan untuk merubah kata tidak baku menjadi kata baku. Berdasarkan hasil pengujian dengan nilai masing-masing *accuracy*, *precision*, *recall*, dan *f-measure* sebesar 98.33%, 96.77%, 100%, dan 98.36%. Melihat hasil evaluasi tersebut, peneliti akan membangun sebuah sistem analisis sentimen terhadap kuliah daring yang dituliskan masyarakat di *Twitter* menggunakan metode klasifikasi *Naïve Bayes*. Selain perubahan kata baku, terdapat hal lain yang dapat membantu untuk meningkatkan kinerja analisis sentimen yaitu dengan penggunaan *stopword* untuk menghilangkan kata yang kurang relevan. Berdasarkan penelitian Evaluasi Daftar *Stopword* oleh (Rahutomo, 2019) terdapat beberapa daftar *stopword* Bahasa Indonesia yang dapat digunakan yaitu daftar yang disusun oleh Fadillah Z. Tala, Damian Doyle, dan Wibisono. Dalam penelitian tersebut, peneliti memberi saran untuk penelitian berikutnya yaitu pembuatan daftar *stopword* secara dinamis sesuai dengan kerja sistem yang dibutuhkan. Oleh karena itu pada penelitian kali ini, peneliti akan membuat daftar *stopword* dinamik dengan algoritme *Term Based Random Sampling*.

*Term Based Random Sampling* adalah suatu algoritme yang dapat digunakan untuk menghasilkan *stopword* secara otomatis berdasarkan seberapa informatif kata tertentu (Lo, et al., 2005). Dalam algoritme tersebut terdapat 3 parameter utama yang dapat mempengaruhi hasil dari *stopword* yang dihasilkan yaitu Y untuk jumlah perulangan pengambilan kata *random*, X untuk jumlah pengambilan bobot terendah dalam perulangan Y, dan L sebagai persentase jumlah *stopword* yang ingin digunakan. Adapun penelitian sebelumnya oleh sebelumnya (Sa'rony, et al., 2019) yang menggunakan *Term Based Random Sampling* sebagai algoritme pembentukan *stopword*. Data yang digunakan adalah *tweet* terkait kebijakan pemerintahan ibukota Republik Indonesia. Berdasarkan hasil pengujian didapatkan akurasi tertinggi disaat parameter L atau persentase *stoplists* senilai 20% dengan *macroaverage accuracy*, *macroaverage precision*, *macroaverage recall*, *macroaverage f-measure* yang masing-masing 0,94, 0,945, 0,94, dan 0,938. Namun, dalam penelitian tersebut peneliti sebelumnya hanya meneliti terkait parameter L, dan tidak meneliti terkait 2 parameter lainnya yaitu X, dan Y. Melihat uraian diatas, penulis memutuskan untuk melakukan penelitian menggunakan *Naïve Bayes* dengan pembentukan *stopword* dengan *Term Based Random Sampling* dengan klasifikasi akan dibuat menjadi 3 kelas yaitu opini netral, positif dan negatif sesuai dari saran penelitian analisis sentimen sebelumnya (Sa'rony, et al., 2019) serta penelitian difokuskan mencari pengaruh serta kombinasi parameter terbaik dalam *Term Based Random Sampling*. Sehingga diharapkan penelitian ini dapat melihat bagaimana pengaruh dari parameter-parameter *Term Based Random Sampling* tersebut.

## 2. METODE PENELITIAN

### 2.1 Text Preprocessing

*Text Preprocessing* ataupun pemrosesan teks merupakan proses penggalian serta mengolah informasi tekstual dengan tujuan untuk kemudahan kebutuhan pemakai sesuai format yang diperlukan sehingga dapat diolah lebih lanjut (Viky, et al., 2018). Teks *pre-processing* ini meliputi, *case folding* atau merubah huruf menjadi kecil, *cleaning* atau menghilangkan *non-alphabet*, tokenisasi atau memisahkan setiap kata, *stopword removal* atau menghapus kata-kata yang tidak relevan dan yang terakhir adalah *stemming* atau mengubah kata-kata menjadi kata dasar (Kalra, et al., 2017).

### 2.2 Term Based Random Sampling

*Term Based Random Sampling* adalah suatu metode yang dapat digunakan untuk menghasilkan daftar *stopword* secara otomatis berdasarkan seberapa informatif kata tertentu (Lo, et al., 2005). Kita dapat mengetahui apakah kata tersebut *stopword* atau bukan dengan melihat kepentingannya, semakin tidak penting kata tersebut, maka lebih tinggi pula kata tersebut memiliki kemungkinan menjadi *stopword*. Untuk mencari nilai kepentingan dari suatu *term* dapat dilakukan dengan perhitungan dengan rumus dari teori *Kullback-Leibler*. Dengan rumus tersebut kita dapat memberi bobot dari suatu *term* pada dokumen sampel yang direpresentasikan dalam Persamaan 1.

$$w(t) = P_x \cdot \log_2\left(\frac{P_x}{P_c}\right) \quad (1)$$

Yang dimana  $P_x$  direpresentasikan dalam Persamaan 2 dan  $P_c$  direpresentasikan dalam Persamaan 3.

$$P_x = \frac{tf_x}{l_x} \quad (2)$$

$$P_c = \frac{F}{token_c} \quad (3)$$

Keterangan:

- $w(t)$  : bobot *term* t pada dokumen sampel
- $tf_x$  : frekuensi kueri *term* dalam dokumen sampel
- $l_x$  : jumlah dari panjang dokumen sampel
- $F$  : frekuensi kueri *term* dari keseluruhan dokumen
- $token_c$  : total token dari keseluruhan dokumen

Dalam perhitungannya dilakukan pemilihan acak *term* dari keseluruhan *term*, lalu kemudian ambil dokumen yang mengandung *term* tersebut dan cari semua *term* dalam dokumen tersebut. Setiap *term* dalam dokumen tersebut akan dilakukan perhitungan bobot menggunakan *Kullback-Leibler*. Lalu setelah perhitungan bobot, diambil sejumlah  $X$  *term* yang diurutkan dari bobot terendah yang dimana  $X$  adalah parameter yang dapat diubah-ubah nantinya. Dalam prosesnya pemilihan *term* acak ini dilakukan

sebanyak  $Y$  kali dimana  $Y$  adalah sebuah parameter yang dapat diisi secara manual untuk mendapatkan hasil yang terbaik. Setelah melakukan proses yang dijelaskan sebelumnya dihitung rata-rata keseluruhan bobot yang didapat oleh *term* lalu diambil sejumlah  $L$  dimana  $L$  adalah parameter yang dapat diubah nantinya.  $L$  adalah parameter yang menentukan berapa jumlah daftar *stopword* yang ingin digunakan.

### 2.3 Term Frequency – Inverse Document Frequency

Pada tahap ini dilakukan pembobotan kata yang merepresentasikan kata-kata tersebut untuk dilakukan perhitungan nantinya. Salah satu metode dalam *term weighting* yang sering digunakan adalah *Term Frequency – Inverse Document Frequency (tf. idf)* (Jones, 2004). Algoritma Term Frequency – Inverse Document Frequency (TF-IDF) berasal dari bidang information retrieval, yang saat ini banyak digunakan untuk perbandingan dokumen (Ryansyah, et al., 2017). Metode *TF-IDF* adalah penggabungan dua metode untuk melakukan pembobotan kata. *TF* atau *Term Frequency* merupakan suatu nilai yang menunjukkan jumlah kemunculan atau frekuensi *term* pada suatu dokumen, dan *IDF* atau *Inverse Document Frequency* adalah perhitungan *inverse* terhadap frekuensi dokumen yang mengandung kata tersebut (Prabowo, et al., 2016). Rumus yang digunakan untuk perhitungan *tf-idf* direpresentasikan pada Persamaan 4 untuk  $\log tf$  dan Persamaan 5 untuk *idf*.

$$tft, d = 1 + \log(ft, d) \quad (4)$$

$$idf(t) = \frac{\log(N)}{df_t} \quad (5)$$

Keterangan:

- $tft, d$  : frekuensi *term* pada dokumen d
- $idf(t)$  : nilai *Inverse Document Frequency* suatu *term* t
- $N$  : total dokumen
- $df(t)$  : nilai *Document Frequency* suatu *term* t

### 2.4 Naïve Bayes Classifier

Algoritme Naïve bayes classifier merupakan metode klasifikasi yang berdasarkan pada kemeungkinan dan Teorema Bayesian dengan asumsi bahwa setiap variabel  $X$  bersifat independen dan tidak ada kaitannya dengan variabel lainnya (Wulan, et al., 2019). Algoritme ini menggunakan metode probabilistik dan statistik. Algoritme ini mencari probabilitas tertinggi untuk proses klasifikasi. Perhitungan Algoritme *Naïve Bayes* direpresentasikan pada Persamaan 6 dan perhitungan *prior* direpresentasikan pada Persamaan 7.

$$P(c|d) = P(c) * P(d|c) \quad (6)$$

$$P(c) = \frac{N_c}{N} \quad (7)$$

Keterangan:

- $P(c|d)$  : *Posterior* atau Probabilitas kelas  $c$  diberikan dokumen  $d$   
 $P(c)$  : *Prior* atau Probabilitas awal muncul kategori  $c$   
 $P(d|c)$  : *Likelihood*  
 $N_c$  : Jumlah dokumen kelas  $c$   
 $N$  : Jumlah seluruh dokumen

Dalam perhitungan *likelihood* atau *conditional probability* salah satu metodenya adalah menggunakan *Multinomial*. Perhitungan *conditional probability* dengan *multinomial* direpresentasikan pada Persamaan 8.

$$P(w|c) = \frac{\text{count}(w, c) + 1}{\text{count}(c) + |V|} \quad (8)$$

Keterangan:

- $P(w|c)$  : *Likelihood*  $w$  dalam kelas  $c$   
 $\text{count}(w, c)$  : Jumlah kemunculan kata  $w$  pada kategori  $c$   
 $\text{count}(c)$  : Jumlah semua total kemunculan kata pada kategori  $c$   
 $|V|$  : Jumlah *term* unik atau fitur

Namun dalam penelitian kali ini digunakan *TF-IDF* sebagai pembobotan sehingga perhitungan *likelihood* atau *conditional probability* direpresentasikan pada Persamaan 9 (Rahman, et al., 2017).

$$P(t_n|c) = \frac{W_{ct} + 1}{(\sum_{w \in V} W'_{ct}) + B'} \quad (9)$$

Keterangan:

- $P(w|c)$  : *Likelihood*  $w$  dalam kelas  $c$   
 $W_{ct}$  : Nilai pembobotan ( $W$ ) *TF-IDF* dari *term*  $t$  di kategori  $c$   
 $\sum_{w \in V} W'_{ct}$  : Jumlah bobot *TF-IDF* seluruh *term* pada kelas  $C$   
 $B'$  : Jumlah *IDF term* pada seluruh dokumen.

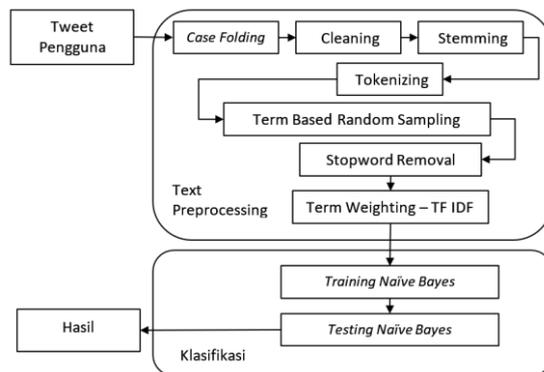
## 2.5 Pengumpulan Data

*Datasets* yang digunakan dalam penelitian ini adalah berupa *tweet* yang berasal dari *Twitter*. Data diambil menggunakan *library Twint* sebagai data *scraper Twitter* untuk *Python* dengan kata kunci “Kuliah Daring” dan “Kuliah Online” yang dikumpulkan pada bulan April 2020 hingga November 2020. Data yang dikumpulkan melalui proses normalisasi secara manual terlebih dahulu. Pada proses *scrapping*, didapatkan sejumlah 600 data *tweet* yang dikumpulkan dari *Twitter*. Namun dalam penelitian ini, data yang digunakan difokuskan untuk memiliki jumlah data yang seimbang dengan tujuan untuk membangun model dengan *fit* agar hasil evaluasi pengujian *stopword Term Based Random Sampling* yang menjadi fokus penelitian ini dapat dihasilkan dari data yang benar-benar seimbang.

Selanjutnya terjadi proses pemberian label keseluruhan 600 data secara manual oleh 5 pakar. Setelah proses pelabelan ditemukan bahwa mayoritas kelas yang didapatkan adalah kelas negatif sehingga peneliti memutuskan untuk mengambil hanya 100 data dari setiap kelas untuk mencapai keseimbangan data setiap kelasnya, sehingga menghasilkan total keseluruhan data yang digunakan berjumlah 300 data.

## 2.6 Perancangan Algoritme

Perancangan Algoritme dibagi menjadi beberapa tahapan yang akan ditampilkan pada Gambar 1.



Gambar 1. Perancangan Algoritme

Perancangan Algoritme diawali dengan melakukan pembuatan daftar *stopword* yang prosesnya diawali dengan *preprocessing* yang meliputi *case folding*, *cleaning*, *tokenizing*, dan *stemming*. *Preprocessing* ini bertujuan untuk merubah data latih berbentuk kumpulan dokumen menjadi *term* untuk dilakukan perhitungan algoritme *Term Based Random Sampling*. Setelah daftar *stopword* hasil dari algoritme *Term Based Random Sampling* didapatkan, selanjutnya data tersebut akan melalui tahap *stopword removal* atau penghapusan kata *stopword* dengan menggunakan daftar *stopword* yang telah dibuat sebelumnya. Setelah didapatkan daftar *term*, langkah selanjutnya adalah proses pembobotan kata dengan menggunakan *tf.idf* untuk merubah kata tersebut menjadi suatu nilai yang nantinya dapat diproses oleh sistem untuk dilatih dan diklasifikasi menggunakan metode *Multinomial Naive Bayes*.

## 3. HASIL DAN PEMBAHASAN

### 3.1 Pengujian Kombinasi Parameter X, Y, dan L terbaik

Pengujian kombinasi parameter  $X$ ,  $Y$ , dan  $L$  dilakukan untuk mengetahui kombinasi terbaik parameter yang digunakan terhadap hasil evaluasi. Pada pengujian ini dilakukan metode *K-Fold Cross Validation* dengan membagi data menjadi  $k$  subset dengan jumlah data yang sama (Rosdiana, et al., 2019). Dalam penelitian ini  $k$  yang digunakan adalah 10. Hasil evaluasi pengujian pengaruh parameter  $X$ ,

Y, dan L yang sudah diurutkan berdasarkan akurasi akan ditampilkan pada Tabel 1.

Tabel 1. 10 Hasil Pengujian pengaruh X, Y, dan L terbaik

X	Y	L	Accuracy	Precision	Recall	F-Measure
10	10	40	75,8%	65,8%	63,6%	64,7%
40	30	10	75,6%	65,3%	63,3%	64,3%
20	20	20	75,4%	64,7%	63,3%	64,3%
50	50	20	75,4%	64,6%	62,9%	63,7%
10	50	50	75,3%	64,7%	63%	63,8%
40	10	10	75,2%	65,1%	62,8%	63,9%
30	40	10	75,2%	64,9%	62,8%	63,8%
10	30	10	75,1%	64,7%	62,6%	63,6%
30	10	20	75,1%	64,4%	62,6%	63,4%
10	10	10	75%	64,4%	62,5%	63,4%

Berdasarkan pada Tabel 1 didapatkan bahwa kombinasi dengan nilai X bernilai 10, Y bernilai 10, dan L bernilai 40 memiliki akurasi terbaik dengan nilai 75.8%.

### 3.2 Pengujian Perbandingan *stopword Term Based Random Sampling* dengan tanpa *Stopword Removal*

Pada pengujian ini ditujukan untuk membandingkan hasil evaluasi yang didapatkan jika menggunakan *Stopword Term Based Random Sampling* dan dibandingkan dengan tanpa menggunakan *Stopword Removal*. Penggunaan parameter yang digunakan dalam proses pembuatan *stopword* dengan *Term Based Random Sampling* sesuai dengan pengujian sebelumnya yang memiliki nilai akurasi terbaik yaitu dengan X bernilai 10, Y bernilai 10, dan L bernilai 40. Hasil pengujian perbandingan *stopword Term Based Random Sampling* dengan tanpa proses *Stopword Removal* akan ditampilkan pada Tabel 2.

Tabel 2 Hasil Pengujian tanpa *stopword* dan TBRS

Stopword	Accuracy	Precision	Recall	F-Measure
Tanpa Stopword	75,3%	64,7%	63%	63,8%
TBRS	75,8%	65,8%	63,6%	64,7%

Pada Tabel 2 didapatkan bahwa hasil evaluasi menggunakan *Term Based Random Sampling* sedikit lebih baik jika dibandingkan tanpa menggunakan *stopword*.

### 3.3 Pengujian Perbandingan Stopword Tala dan *Stopword Term Based Random Sampling*

Pada pengujian ini ditujukan untuk membandingkan hasil evaluasi yang didapatkan jika menggunakan *stopword* Tala dan dibandingkan dengan *stopword* yang dihasilkan oleh algoritme *Term Based Random Sampling*. Penggunaan parameter yang digunakan dalam proses pembuatan *stopword* dengan *Term Based Random Sampling* sesuai dengan pengujian sebelumnya yang memiliki nilai akurasi terbaik yaitu dengan X bernilai 10, Y

bernilai 10, dan L bernilai 40. Hasil pengujian perbandingan *stopword Term Based Random Sampling* dengan *stopword* Tala yang akan ditunjukkan pada Tabel 3.

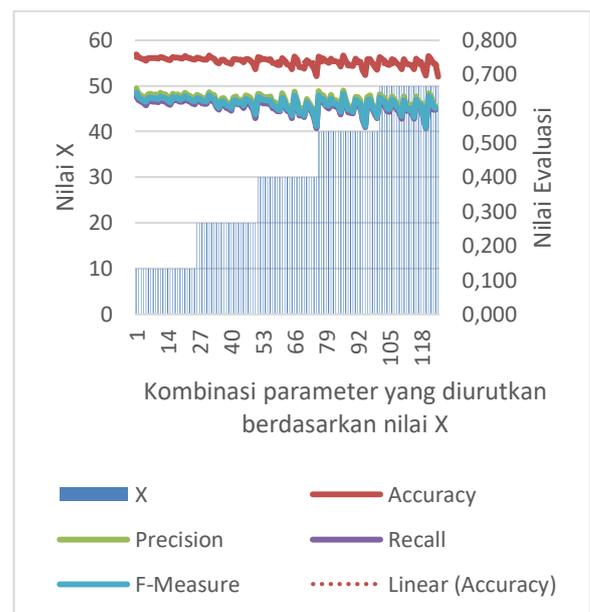
Tabel 3 Hasil Pengujian *stopword* Tala dan TBRS

Stopword	Accuracy	Precision	Recall	F-Measure
Tala	73,8%	61,9%	60,7%	61,3%
TBRS	75,8%	65,8%	63,6%	64,7%

Pada Tabel 3 didapatkan bahwa akurasi keseluruhan dari penggunaan metode *Term Based Random Sampling* 2% lebih baik dibandingkan dengan penggunaan *stopword* Tala.

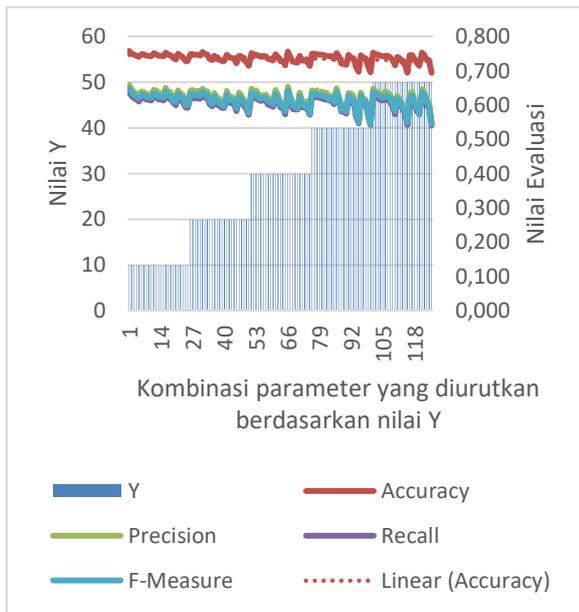
### 3.4 Hasil Analisis

Pengujian kombinasi parameter X, Y, dan L dilakukan untuk mencari kombinasi parameter yang paling baik serta pengaruh tiap parameternya dalam evaluasi sistem. Grafik hasil pengujian parameter pengaruh X, Y, dan L dapat dilihat pada Gambar 2, Gambar 3, dan Gambar 4.

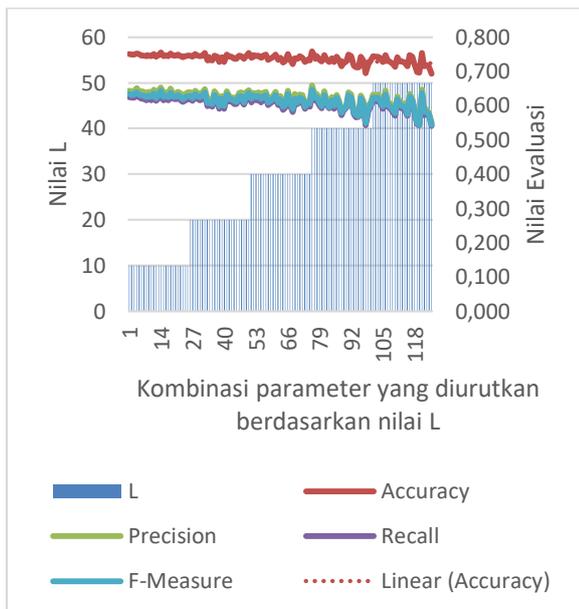


Gambar 2. Grafik Pengaruh X

Berdasarkan pada Gambar 2, 3, 4 dapat dilihat pada bagian bawah yang merupakan 125 kombinasi parameter yang sudah diurutkan berdasarkan nilai X, Y, dan L, dan diketahui bahwa garis *accuracy*, *precision*, *recall*, dan *f-measure* semakin kanan semakin menurun menunjukkan bahwa semakin besar nilai X, Y, dan L maka semakin tinggi kemungkinannya untuk *accuracy*, *precision*, *recall*, dan *f-measure* turun. Hal ini dibuktikan ketika X bernilai 10, garis *accuracy* lebih tinggi dan lebih stabil jika dibandingkan dengan X bernilai 50, hal ini berlaku juga untuk kedua parameter lainnya yaitu Y dan L.



Gambar 3. Grafik Pengaruh Y



Gambar 4. Grafik Pengaruh L

Dapat dilihat juga bahwa ketiga grafik tersebut bersifat fluktuatif, hal ini terjadi karena disaat parameter tersebut digunakan, terdapat pengaruh parameter-parameter lainnya yang mempengaruhi hasil evaluasi. Alasan yang menggambarkan mengapa terjadinya fluktuatif nilai *accuracy*, *precision*, *recall* dan *f-measure* dapat dilihat pada Tabel 4.

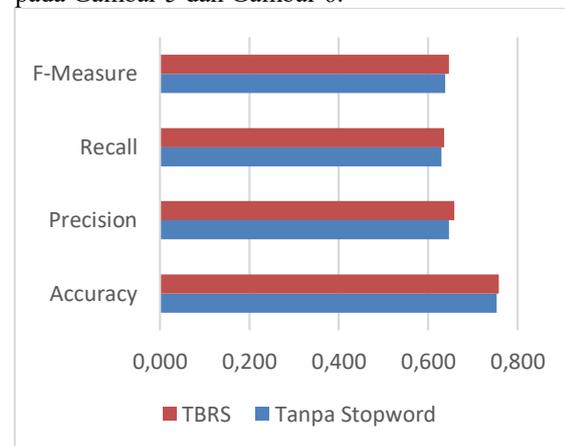
Tabel 4 Pengaruh Parameter

X	Y	L	Accuracy	Precision	Recall	F-Measure
10	10	40	75,8%	65,8%	63,6%	64,7%
30	50	40	69,5%	55,7%	54,2%	54,9%

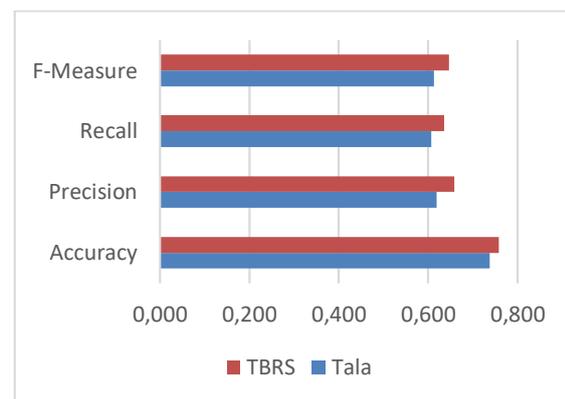
Dapat dilihat dalam Tabel 4 terdapat 2 kombinasi parameter yang keduanya menggunakan nilai L sebesar 40, namun terjadi perbedaan yang signifikan antara perbandingan *accuracy*, *precision*, *recall*, dan

*f-measure* yang dimana ketika X dan Y bernilai 10, 10 lebih baik ketika nilai X dan Y bernilai 30, 50.

Pengujian selanjutnya merupakan perbandingan antara algoritme *Term Based Random Sampling*, tanpa menggunakan *stopword*, dan menggunakan *stopword* Tala yang akan ditunjukkan dalam grafik pada Gambar 5 dan Gambar 6.



Gambar 5 Hasil Evaluasi Pengujian Tanpa Stopword dan TBRS



Gambar 6. Hasil Evaluasi Pengujian Tala dan TBRS

Pada Gambar 5 dan Gambar 6 didapatkan bahwa hasil evaluasi keseluruhan dari penggunaan metode *Term Based Random Sampling* ini sedikit lebih baik 0,5% dibandingkan dengan tanpa menggunakan proses *stopword removal* dan 2% lebih baik dibandingkan dengan penggunaan *stopword* Tala. Metode tanpa *stopword* memiliki *macroaverage accuracy* sebesar 75,3%, *macroaverage precision* sebesar 64,7%, *macroaverage recall* sebesar 63,0%, *macroaverage f-measure* sebesar 63,8% dan untuk metode dengan *stopword* Tala *macroaverage accuracy* sebesar 73,8%, *macroaverage precision* sebesar 61,9%, *macroaverage recall* sebesar 60,7%, *macroaverage f-measure* sebesar 61,3% memiliki sedangkan untuk metode dengan *Term Based Random Sampling* memiliki *macroaverage accuracy* sebesar 75,8%, *macroaverage precision* sebesar 65,8%, *macroaverage recall* sebesar 63,6%, *macroaverage f-measure* sebesar 64,7%. Sehingga dapat disimpulkan bahwa penggunaan *Term Based Random Sampling* sedikit lebih baik dalam kasus ini.

#### 4. KESIMPULAN DAN SARAN

Berdasarkan pengujian yang sudah dilakukan terhadap parameter X, Y, dan L bahwa semakin besar nilai X, Y, dan L maka semakin tinggi pula kemungkinannya evaluasi sistem untuk menurun. Hal ini dibuktikan ketika X bernilai 10, hasil evaluasi lebih tinggi dan lebih stabil jika dibandingkan dengan X ketika bernilai 50, hal ini berlaku juga untuk kedua parameter lainnya yaitu Y dan L.

Penggunaan metode pembentukan *stopword Term Based Random Sampling* untuk analisis sentimen dengan *Naïve Bayes* dapat diterapkan dengan baik, hal ini dapat dibuktikan dengan meningkatnya akurasi sistem yang dilakukan sebanyak 10-fold ketika menggunakan *stopword Term Based Random Sampling* sebesar 0,5% jika dibandingkan dengan tidak menggunakan proses *stopword removal*.

Berdasarkan pengujian perbandingan antara *Naïve Bayes* dan *stopword Term Based Random Sampling* mendapatkan rata-rata akurasi dari 10-fold, *stopword Term Based Random Sampling* memiliki akurasi sebesar 75,8% sedangkan jika menggunakan *stopword* Tala adalah sebesar 73,8%. Penggunaan *stopword Term Based Random Sampling* terbukti dapat meningkatkan akurasi pada analisis sentimen dengan *Naïve Bayes* sebesar 2%.

Adapun saran yang dapat membuat penelitian lebih baik adalah adanya normalisasi kata atau perbaikan kata pada tahap *pre-processing* terhadap *tweet* yang memiliki kesalahan penulisan kata. Selain itu data yang digunakan lebih baik dalam pemilihannya.

#### DAFTAR PUSTAKA

- ARNANI, M., 2020. Kasus pertama virus corona di China dilacak hingga 17 November 2019. KOMPAS. [online] Tersedia di: <<https://www.kompas.com/tren/read/2020/03/13/111245765/kasus-pertama-virus-corona-di-china-dilacak-hingga-17-november-2019>> [Diakses 1 September 2020]
- DILA PURNAMA SARI, D. E., SARI, Y. A. & FURQON, M. T., 2020. Pembentukan Daftar Stopword menggunakan Zipf Law dan Pembobotan Augmented TF - Probability IDF pada Klasifikasi Dokumen Ulasan Produk. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, pp. 406-412.
- JONES, S., 2004. A Statistical Interpretation of Term Specificity and Its Retrieval. *Journal Of Documentation*, 60(5), pp. 11-21.
- KALRA, V. & AGGARWAL, R., 2017. Importance of Text Data Preprocessing & Implementation in RapidMiner. In: *Proceedings of the First International Conference on Information Technology and Knowledge Management*. New Delhi, pp. 71-75.
- LO, R. T.-W., HE, B. & OUNIS, I., 2005. *Automatically Building a Stopword List for an Information Retrieval System*, Glasgow, UK: Department of Computing Science.
- PRABOWO, D. A., FHADLI, M., NAJIB, M. A. & FAUZI, H. A., 2016. TF-IDF-Enhanced Genetic Algorithm Untuk Extractive Automatic Text Summarization. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 3(3), pp. 208-215.
- RAHMAN, A., WIRANTO & DOEWES, A., 2017. Online News Classification Using Multinomial Naive Bayes. *ITSMART: Jurnal Ilmiah Teknologi dan Informasi*, 6(1).
- RAHUTOMO, F. & RIRID, A. R. T. H., 2018. EVALUASI DAFTAR STOPWORD BAHASA INDONESIA. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, pp. 41-48.
- ROSDIANA., TUNGADI, E., SAHARUNA, Z., NUR, M. Y. U., 2019. Analisis Sentimen pada Twitter terhadap Pelayanan Pemerintah Kota Makassar. *Conference Seminar Nasional Teknik Elektro dan Informatika 2019 Makassar, Indonesia*.
- RYANSYAH, A. & ANDAYANI, S., 2017. Implementasi Algoritma TF-IDF pada Pengukuran Kesamaan Dokumen JuSiTik *Jurnal Sistem dan Teknologi Informasi Komunikasi*, pp. 1-10.
- SA'RONY, A., ADIKARA, P. P. & WIHANDIKA, R. C., 2019. Analisis Sentimen Kebijakan Pemindahan Ibukota Republik Indonesia dengan Menggunakan Algoritme Term-Based Random Sampling dan Metode Klasifikasi Naïve Bayes. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 10086-10094.
- SARI, F. V. & WIBOWO, A., 2019. ANALISIS SENTIMEN PELANGGAN TOKO ONLINE JD.ID MENGGUNAKAN METODE NAÏVE BAYES CLASSIFIER BERBASIS KONVERSI IKON EMOSI. *Simetris: Jurnal Teknik Mesin, Elektro dan Ilmu Komputer*, pp. 681-686.
- VIKY, A. S. & ZULIARSO, E., 2018. Analisis Sentimen Twitter menggunakan Text Mining dengan Algoritme Naïve Bayes Classifier. *Jurnal Dinamika Informatika* 10(2), pp 69-73.
- WULAN, S. U. V., AFIF, A. S. & ABDURRACHMAN, F. B., 2019. Analisis Sentimen Evaluasi Kinerja Dosen menggunakan *Term Frequency-Inverse Document Frequency* dan *Naïve Bayes Classifier*. *Jurnal Pengembangan Teknologi*

Informasi dan Ilmu Komputer (JPTIHK),  
3(6), pp. 6080-6088.

ZULI, A. A., SOFYAN, A. A. & ADRIAN, M. J. H.,  
2020. Analisis Sentimen *Movie Review*  
Menggunakan Naïve Bayes Classifier  
dengan Seleksi Fitur *Chi Square*. Jurnal  
BITe, 2(1), pp. 40-44.