

## Mapping Opini Publik Terhadap Calon PNS Yang Mundur Setelah Lolos Dengan Teknik Berbasis *Multinomial Naive Bayes*

### *Mapping Public Opinion To Candidate Civil Servants Which Reverse After Get Away With Multinomial Naïve Bayes Based Technique*

Rizmawan Iqbal Lutfi<sup>1</sup>, Bagus Setya Rintyarna<sup>2</sup>, Wiwik Suharso<sup>3</sup>

<sup>1</sup>Mahasiswa Fakultas Teknik, Universitas Muhammadiyah Jember  
email: mawaniqbal29@gmail.com

<sup>2</sup>Dosen Fakultas Teknik, Universitas Muhammadiyah Jember  
email: Bagus.setya@unmuhjember.ac.id

<sup>3</sup>Dosen Fakultas Teknik, Universitas Muhammadiyah Jember  
email: wiwiksuharso@unmuhjember.ac.id

#### Abstrak

Sejumlah 105 calon pegawai negeri sipil yang lolos seleksi tahun 2021 ditemukan mundur dan menyebabkan komentar netizen Indonesia melalui media sosial terutama *YouTube*. Komentar pengguna *YouTube* digunakan untuk melihat seberapa besar sentimen negatif, positif, netral sehingga menjadi sumber analisis penelitian, menganalisis komentar dimaksud untuk mengetahui dampak video dan umpan balik publik berupa sentimen positif atau negatif mengenai pengunduran diri calon pegawai negeri sipil yang lolos seleksi melalui video di chanel *YouTobe*. Penelitian ini akan membandingkan hasil akurasi, presisi, *recall* dan *f-measure* dari proses klasifikasi *Multinomial Naïve Bayes* setelah dan tanpa menggunakan seleksi fitur *Chi-Square*. Hasil performa akurasi, presisi, *recall*, *f-measure* tertinggi yang dihasilkan metode *Multinomial Naïve Bayes* tanpa seleksi fitur *Chi-Square* menghasilkan nilai 55%. Sedangkan hasil performa akurasi tertinggi metode *Multinomial Naïve Bayes* menggunakan seleksi fitur *Chi-Square* dengan 400 fitur diperoleh nilai 82%, nilai presisi 82%, nilai *recall* sebesar 81%, nilai *f-measure* sebesar 82%. Pada penelitian ini seleksi fitur *Chi-Square* dapat meningkatkan performa akurasi, presisi, *recall* dan *f-measure*

**Keywords:** Analisis Sentimen, *Chi-Square*, *Multinomial Naïve Bayes*, *TF-IDF*, *YouTube*

#### Abstract

A total of 105 civil servant candidates who passed the 2021 selection were found to have withdrawn and this caused comments from Indonesian netizens via social media, especially *YouTube*. *YouTube* user comments are used to see how much negative, positive, neutral sentiment there is so that it becomes a source of research analysis, analyzing the comments in question to find out the impact of the video and public feedback in the form of positive or negative sentiment regarding the resignation of civil servant candidates who pass the selection via video on the channel *YouTube*. This research will compare the results of accuracy, precision, recall and *f-measure* from the *Multinomial Naïve Bayes* classification process after and without using *Chi-Square* feature selection. The highest performance results of accuracy, precision, recall, *f-measure* produced by the multinomial naïve Bayes method without *Chi-Square* feature selection produced a value of 55%. Meanwhile, the results of the highest accuracy performance of the multinomial naïve Bayes method using *Chi-Square* feature selection with 400 features obtained a value of 82%, a precision value of 82%, a recall value of 81%, an *f-measure* value of 82%. In this research, *chi-square* feature selection can improve accuracy, precision, recall and *f-measure* performance.

**Keywords:** Sentiment Analysis, *Chi-Square*, *Multinomial Naïve Bayes*, *TF-IDF*, *YouTube*

## 1. PENDAHULUAN

Sejumlah 105 calon pegawai negeri sipil (CPNS) yang sudah lolos tes seleksi penerimaan tahun 2021 ditemukan mundur dan menarik diri, berbagai alasan mengundurkan diri seperti lokasi kerja, gaji, dan tunjangan yang tidak sesuai dengan ekspektasi, dan juga hilangnya motivasi. Pengunduran CPNS menyebabkan kerugian negara karena biaya yang digunakan untuk menyelenggarakan seleksi CPNS cukup besar, peserta CPNS yang mengundurkan diri bisa dikenakan sanksi denda mulai dari Rp. 25.000.0000 sampai Rp. 100.000.000 (Dzulfaroh, 2022). Pengunduran diri ratusan CPNS menjadi fenomena baru dan menyebabkan tanggapan dan komentar di tengah masyarakat dan netizen Indonesia yang di zaman milenial ini kecepatan teknologi sudah tidak perlu diragukan lagi, seperti berita melalui sejumlah platform di media sosial terutama *YouTube*.

*YouTube* merupakan salah satu *platform* media sosial yang banyak penggunaannya. Pembaruan pada *Google Advertising* menunjukkan bahwa *YouTube* memiliki 139 juta pengguna di Indonesia pada awal 2022 (Kemp. S, 2022). *YouTube* bisa digunakan untuk berinteraksi dan menyediakan tempat untuk menilai suatu video bisa berupa komentar. *YouTube* menyediakan mekanisme interaksi sosial untuk mendapatkan opini dan *views* dari pengunjung melalui komentar, peringkat, pilihan favorit, rekomendasi berbagi, rekomendasi tayangan, dan komentar positif dan negatif dari pengguna (Wirga, 2017). *YouTube* bisa digunakan untuk menilai suatu video bisa berupa komentar. Komentar pengguna *YouTube* dapat digunakan sebagai informasi yang penting sebagai indikator untuk melihat seberapa besar sentimen negatif, sentimen positif ataupun netral terhadap komentar publik terhadap pengunduran diri beberapa CPNS yang lolos seleksi, sehingga data komentar

tersebut bisa menjadi sumber analisis penelitian, Adapun teknik dalam menganalisis komentar, opini, respon publik dan tanggapan pada suatu konten video yang ada di *YouTube* adalah analisis sentimen.

Analisis Sentimen adalah praktik penerapan pemrosesan bahasa alami dan teknik analisis teks untuk mengidentifikasi dan mengekstrak informasi subjektif dari teks (Hussein, 2018). Dengan banyaknya hubungan sosial pada *platform Youtube* dan implementasi sentimen analisis video *Youtube* yang dimaksud untuk mengetahui dampak dari sebuah video di situs *YouTube* dan umpan balik publik berupa sentimen positif atau negatif mengenai pengunduran diri beberapa CPNS yang lolos seleksi melalui postingan video yang diunggah di chanel *YouTobe*.

Berbagai macam penelitian terkait sentimen analisis yaitu menggunakan metode Naïve Bayes, KNN dan SVM. Metode *Majority Vote* yang digunakan oleh (Pradana, 2021) Data yang digunakan yaitu data *comment YouTube* berbahasa Inggris pada review produk, dengan klasifikasi dengan tiga kategori yaitu positif, negatif, dan netral dan metode yang digunakan yaitu SVM, KNN dan Naïve Bayes, akan dibandingkan dengan *Majority vote*. Kesimpulan yang diperoleh dengan memanfaatkan 100 data untuk memperoleh akurasi sebanyak 0.8 dan diperoleh nilai akurasi 0.48 dengan 50 data uji.

Pada penelitian yang serupa yang dilakukan oleh (EM Sipayung, 2016) merancang sistem analisis sentimen komentar pelanggan pada hotel dari 175 data dibagi dengan data latih dengan dua bagian klasifikasi kategori dan klasifikasi sentimen dengan metode *Naïve Bayes Classifier* didapatkan hasil akurasi sistem yaitu 77.14% dan untuk kategori sentimen, Presisi sebanyak 99.12% *Recall* 72.9% dan Akurasi 75.42%

Berdasarkan dari latar belakang yang sudah di jelaskan maka penelitian tugas akhir ini akan berjudul “Mapping Opini Publik Terhadap Calon PNS Yang Mundur Setelah Lolos Seleksi Dengan Teknik Berbasis Multinomial Naïve Bayes ”.

## 2. TINJAUAN PUSTAKA

### A. Text Mining

*Text Mining* adalah sebuah proses mengekstrak informasi dan pengetahuan yang berguna dari sumber data tak struktur dalam bentuk teks dengan kata yang tidak struktur, seperti dokumen, pdf, word, komentar, *review* dan lain lain (Siregar, Sinaga, Arianto, 2017).

### B. Text Preprocessing

*Text Preprocessing* merupakan proses yang dilakukan untuk memilih data untuk diproses oleh sistem. Ini menghasilkan data yang baik dan terstruktur dengan baik juga meningkatkan akurasi dari pembelajaran mesin yang diproses. Pada tahap *preprocessing* dilakukan penyiapan dokumen mentah menjadi dokumen atau representatif dokumen yang siap diproses (Zaman dan Winarko, 2011).Berikut adalah proses dalam melakukan *text preprocessing* :

#### a) Cleansing

*Cleansing* adalah proses membersihkan data dengan menghilangkan huruf, tanda baca, angka, *Hashtag*, URL, bahkan kata yang tidak diinginkan dari data yang akan dilakukan penelitian, tujuannya untuk mengurangi noise yang menyebabkan proses klasifikasi menjadi kurang maksimal (Yulita, Nugroho & Algifari, 2021)

#### b) Case Folding

*Case folding* adalah proses perubahan karakter pada data semua huruf, Karakter yang bisa diterima hanya berupa huruf ‘a’ sampai dengan ‘z’ dan diubah ke huruf kecil, karakter selain huruf akan dihilangkan atau dianggap delimiter (Balya, 2019).

#### c) Stopword Removal

*Stopword Removal* adalah proses menghilangkan kata-kata yang diambil dari daftar *stopword*. *Stoplist/stopword* merupakan kata-kata yang tidak memiliki arti atau deskripsi

yang dapat dibuang dengan pendekatan *bag-of-words*. Contoh *stopwords* yaitu seperti “dan”, “yang”, “dari”.”di” (Setiawan, ea al, 2015).

#### d) Stemming

*Stemming* adalah proses mengubah kata, menghilangkan imbuhan - imbuhan baik awalan maupun akhiran pada dalam dokumen teks menjadi kata dasar (Mutawalli, 2019)

#### e) Normalisasi Bahasa

Normalisasi Bahasa merupakan tahap *pre-processing* kata yang tidak baku tujuannya untuk membalikkan bentuk penulisan dari setiap kata yang sesuai menurut Kamus Besar Bahasa Indonesia (KBBI). Prosedur ini dibuat dengan menyelaraskan masing-masing kata dalam dokumen data latih atau data uji dengan kata dalam kamus bahasa yang tidak baku (Luqyana, 2018)

#### f) Tokenizing

*Tokenizing* adalah proses mengklasifikasikan dokumen teks bagian-bagian tertentu (kalimat atau paragraf). Fase ini dilakukan untuk membantu menambah bobot pada setiap kata (Istiqomah, 2021).

## C. Analisis Sentimen

Analisis sentimen dapat digambarkan sebagai, pendapat, emosi, ide atau keputusan sebagai sumber utama informasi. Informasi berupa teks ini digunakan untuk menganalisis ekspresi sentimen dan menghitung klasifikasinya (Astari dan Wahib Rozaqi, 2021)

## D.YouTobe

*YouTobe* adalah situs web berbagi video paling populer dan salah satu platform media online terbesar yang difungsikan untuk mengunggah, menonton sejumlah video yang tidak terbatas, dan berbagi video oleh individu, kelompok maupun perusahaan – perusahaan, selain itu di *YouTube* terdapat beberapa fitur seperti *like*, *share*, dan *form* komentar bisa difungsikan sebagai komentar bahan diskusi, asumsi tanggapan pengguna (Agarwal, 2015).

## E. Term Frequency-Inverse Document Frequency (TF-IDF)

*Term Frequency-Inverse Document Frequency* (TF-IDF) merupakan metode yang digunakan untuk melakukan pembobotan pada

setiap kata (*term*) yang muncul di dalam suatu dokumen, proses pembobotan TF-IDF dimulai dengan *Term Frequency* (TF) untuk menghitung tiap *term*/kata yang ada pada setiap kemunculan *term* dalam dokumen. Kemudian *Document Frequency* (DF) untuk menghitung *Inverse Document Frequency* (IDF) dan terakhir nilai TF dikalikan dengan IDF, Bobot suatu kata akan semakin besar asalkan sering muncul dalam suatu dokumen dan semakin kecil asalkan kata tersebut muncul dalam banyak dokumen (Manning et al., 2009).

TF merupakan frekuensi kemunculan kata pada tiap dokumen yang diberikan menunjukkan seberapa penting kata itu dalam tiap dokumen (Mishra & Urolagin, 2019). Dalam menghitung TF ditunjukkan pada persamaan berikut ini :

$$tf_{t,d} = \frac{n_{t,d}}{N} \quad (2.1)$$

Keterangan :

$n_{t,d}$  = nilai istilah yang muncul dalam dokumen  
 $N$  = jumlah term dalam dokumen  
 $tf_{t,d}$  = frekuensi kemunculan kata pada sebuah dokumen.

Setelah berhasil mendapatkan nilai *TF*, selanjutnya adalah menghitung nilai *IDF*, dimana nilai *IDF* digunakan untuk mengukur seberapa pentingnya sebuah kata (Kamyab, et al, 2021). Berikut adalah rumus yang digunakan untuk menentukan nilai *IDF* yang ditunjukkan pada persamaan berikut ini :

$$idf_d = \log\left(\frac{N_d}{df}\right) \quad (2.2)$$

Keterangan :

$N$  = total keseluruhan dokumen  
 $df$  = banyak dokumen yang mengandung term tersebut  
 $idf_d$  = jumlah kemunculan suatu kata dalam dokumen.

Setelah nilai *IDF* berhasil ditemukan. Maka kita dapat menentukan nilai sebuah TF-IDF. Hasil TF-IDF ini adalah hasil perkalian dari TF dikalikan dengan IDF yang ditunjukkan pada persamaan berikut ini :

$$tf.idf_{t,d} = tf_{t,d} \times idf_d \quad (2.3)$$

Keterangan :

$tf.idf_{t,d}$  = *Term Frequency* – *Inverse Document Frequency*

$tf_{t,d}$  = frekuensi kemunculan kata pada sebuah dokumen.

$idf_{t,d}$  = jumlah kemunculan suatu kata dalam dokumen.

## F. Seleksi Fitur Chi Square

Seleksi fitur bertujuan untuk menghilangkan fitur yang menghambat proses klasifikasi, beberapa seleksi fitur adalah *Chi Square*. *Chi Square* salah satu seleksi fitur *supervised* mampu memilih fitur dan dapat menghapus banyak fitur tanpa mempengaruhi akurasi. Proses seleksi fitur memiliki pengaruh tinggi akan digunakan untuk proses klasifikasi dilakukan dengan mengurutkan setiap fitur dari nilai yang tertinggi ke nilai terendah (Ling et al., 2014). Berikut perhitungan yang dipakai untuk menentukan nilai seleksi fitur *Chi – Square*

$$\chi^2(t, c) = \frac{N(AxD - CxB)^2}{(A + C)(B + D)(A + B)(C + D)} \quad (2.4)$$

Keterangan :

$t$  : Kata  
 $c$  : Kelas/Kategori  
 $N$  : Jumlah dokumen latih  
 $A$  : Jumlah banyaknya dokumen pada kategori  $c$  yang mengandung  $t$   
 $B$  : Jumlah banyaknya dokumen bukan kategori  $c$  yang mengandung  $t$   
 $C$  : Jumlah banyaknya dokumen pada kategori  $c$  yang tidak mengandung  $t$   
 $D$  : Jumlah banyaknya dokumen bukan kategori  $c$  yang tidak mengandung  $t$

## G. Multinomial Naïve Bayes (MNB)

*Multinomial Naïve Bayes* merupakan pengembangan model dari algoritma bayes yang biasa digunakan dalam klasifikasi teks (McCallum & Nigam, 1998).

Menurut Setiawan (2021), model *Multinomial Naïve Bayes* menggunakan rumus sebagai berikut:

$$P(c|term\ dokumen\ d) = P(c) \times P(t_1|c) \times P(t_2|c) \times P(t_3|c) \times \dots \times P(t_n|c) \quad (2.5)$$

Keterangan:

$P(c)$  : Probabilitas *prior* dari variabel kelas  $c$   
 $t_n$  : Kata dokumen  $d$  ke- $n$

$P(c|term\ dokumen\ d)$  : Probabilitas suatu dokumen termasuk kategori

$P(t_n | c)$  : Probabilitas kata ke- $n$  dengan diketahui kategori  $c$

Menurut Setiawan (2021), untuk menghitung data prior masing – masing kelas dengan rumus Probabilitas prior kelas  $c$  ditentukan dengan :

$$P(c) = \frac{N_c}{N} \quad (2.6)$$

Keterangan:

$N_c$  = Jumlah kelas  $c$  pada seluruh dokumen.

$N$  = Jumlah seluruh dokumen.

Sementara persamaan *Multinomial Naïve Bayes* yang digunakan untuk pembobotan kata TF-IDF menurut (Mayasari dan Indarti, 2022) adalah sebagai berikut:

$$P(t|c) = \frac{W_{ct} + 1}{(\sum_{W' \in V} W_{ct'}) + B'} \quad (2.7)$$

Keterangan:

$W_{ct} + 1$  : Jumlah Nilai pembobotan TF-IDF term  $t$  pada dokumen di kelas  $c$

$\sum_{W' \in V} W_{ct'}$  : Jumlah bobot TF-IDF dari keseluruhan kata yang berada di kelas  $c$

$B'$  : Jumlah  $W$  kata unik (nilai *idf* tidak dikali dengan *tf*) pada seluruh dokumen

#### H. K-fold Cross Validation

*K-fold Cross Validation* adalah jenis pengujian *cross validation* yang berguna untuk mempartisi data menjadi data pelatihan dan pengujian. Metode ini banyak digunakan oleh peneliti karena dapat mengurangi bias yang terjadi dalam pengambilan sampel, *K-fold Cross Validation* juga berguna dalam mengevaluasi kinerja proses suatu metode algoritma dengan membagi data secara seimbang dan sebanyak nilai *K-fold*. Kemudian  $K$  adalah jumlah partisi data yang digunakan untuk uji latih, salah satu kelompok *k-fold* tersebut akan digunakan sebagai data uji sedangkan sisa kelompok lainnya akan dijadikan sebagai data latih. Berikut gambar pembagian data menggunakan *k-fold cross validation* (Kurniawan, 2017)

#### I. Confusion Matrix

*Confusion Matrix* merupakan metode untuk menghitung dan mengetahui tingkat hasil akurasi suatu sistem klasifikasi. *Confusion Matrix* memproses informasi yaitu tentang klasifikasi yang diprediksi dengan benar dari sebuah sistem klasifikasi.

**Tabel 1.** Visualisasi Confusion Matrix Kelas

	Actual Class Positive	Actual Class Negatif
Predicted Class Positive	True Positive (TP)	False Positive (FP)
Predicted Class Negative	False Negative (FN)	True Negative (TN)

Sumber : Jurnal

Keterangan :

TP (True Positive): jumlah komentar yang diprediksi benar positif yang nilai sebenarnya positif

TN (True Negative): jumlah komentar yang diprediksi negatif yang nilai sebenarnya negatif

FP (False Positive) : jumlah komentar yang diprediksi positif yang nilai sebenarnya negatif

FN (False Negative): jumlah komentar yang diprediksi negatif yang nilai sebenarnya positif

Bermula *confusion matrix* bisa diperoleh nilai akurasi. Nilai akurasi di aplikasi untuk menghitung seberapa akurat suatu model dalam mengklasifikasi kelas dengan benar (Ailiyya, 2020). nilai akurasi untuk *confusion matrix* yang diberikan oleh rumus sebagai berikut.

$$\frac{TP+TN}{TP+TN+FP+FN} = \text{Akurasi} \quad (2.8)$$

Presisi dilakukan untuk memperoleh rentang nilai prediksi benar positif dan dibandingkan dengan seluruh hasil prediksi positif, Dengan cara setelah menentukan nilai TP (*True Positive*) yang akan dibagi dengan TP (*True Positive*) dijumlahkan dengan FP (*False Positive*), sedangkan menentukan Recall Dengan cara setelah menentukan nilai TP (*True Positive*) yang akan dibagi dengan TP (*True Positive*) dijumlahkan dengan FP (*False Negative*) (Kencana, 2019).

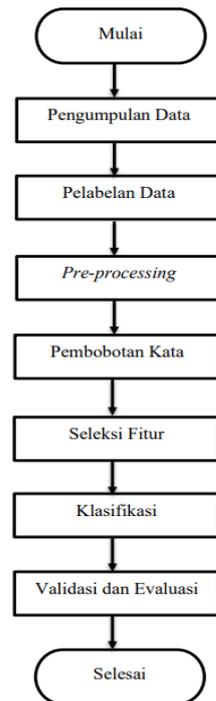
$$\frac{TP}{TP+FP} = \text{Presisi} \quad (2.9)$$

$$\frac{TP}{TP+FN} = \text{Recall} \quad (2.10)$$

*F-measure* adalah nilai yang mewakili keseluruhan kinerja system dan merupakan gabungan nilai *Recall* dan presisi (Ramdani, 2014)

$$\frac{2 \times \text{Recall} \times \text{Presisi}}{\text{Recall} + \text{Presisi}} = F\text{-measure} \quad (2.11)$$

### 3. METODOLOGI PENELITIAN



**Gambar 1.** Metode Penelitian  
 Sumber : Rancangan Sendiri

#### A. Pengumpulan Data dengan *Crawling* Data

Proses *crawling* data dilakukan dengan menggunakan *Google App Script* dan mengambil Video ID *YouTube* pada link video *YouTube* tersebut dan meletakkannya pada *Google Spreadsheet* setelah itu pilih menu ekstensi dan pilih *App Script*, selanjutnya masukkan kode yang sudah disiapkan untuk melakukan *crawling* data jalankan fungsinya. Hasil *crawling* akan di tampilkan pada *Google Spreadsheet*. Dalam penelitian proses *crawling* hanya mengambil data komentar dan disimpan dengan format CSV (*Comma Separated Value*).

#### B. Pelabelan Data

Proses *labelling* sangat memerlukan waktu karena jumlah data yang banyak dan proses

*labelling* dilaksanakan oleh 1 ahli NLP dan 2 orang pakar Bahasa Indonesia. Data yang digunakan pada penelitian ini adalah data komentar video *YouTube* dengan jumlah data sebanyak 1000. Yang terdiri dari 510 data berlabel positif dan 490 data berlabel negatif. Data yang dipakai akan di kategorikan sentimen positif dan negatif dengan pelabelan dilakukan secara manual.

### 4. HASIL DAN PEMBAHASAN

#### A. Text- Preprocessing

*Text Preprocessing* digunakan untuk mengubah data mentah agar menjadi berguna dan efisien untuk pengolahan selanjutnya. Adapun tahapan *text preprocessing* seperti *cleansing*, *case folding*, *stopword removal*, *stemming*, *normalisasi bahasa*, *tokenizing*..

#### B. Pembobotan Kata

Pembobotan kata menggunakan TF-IDF. Algoritma TF-IDF dilakukan untuk menghitung bobot nilai suatu kata, dimulai dengan TF yaitu menghitung setiap term/kata dalam setiap dokumen untuk menunjukkan seberapa penting kata itu dalam tiap dokumen

#### C. Seleksi Fitur

Seleksi fitur dalam penelitian ini menggunakan *Chi-Square* yang berfungsi untuk menyaring atau menyeleksi kata yang akan dijadikan fitur menggunakan fungsi *Chi-Square*.

#### D. Pembagian Data

Pembagian data dilakukan dengan *Cross Validation* dengan membagi data menjadi partisi, Proses *Cross Validation* dilakukan untuk menemukan nilai akurasi dengan menguji beberapa kali untuk mengetahui seberapa baik kinerja model dengan data yang dipakai, Proses Validasi pada penelitian ini menggunakan *K-Fold Cross Validation* yang dipakai nilai *K-fold* adalah *2-fold*, *5-fold*.

#### E. Rekapitulasi Hasil dan Perbandingan Hasil Akurasi, Presisi, *Recall* dan *F-Measure*

Setelah nilai akurasi, presisi, *recall*, dan *F-Measure* telah di dapatkan yaitu menghasilkan fitur dengan jumlah 400 menghasilkan nilai akurasi, presisi, *recall*, *F-Measure* tertinggi dari pada jumlah fitur yang lain, selanjut akan dibandingkan dengan hasil nilai akurasi, presisi, *recall*, *F-Measure* metode *Multinomial Naïve Bayes* yang tertinggi.

**A. Akurasi**

**Tabel 3.** Tabel perbandingan akurasi pada Metode *Multinomial Naïve Bayes* tanpa *Chi-Square* dengan Metode *Multinomial Naïve Bayes* menggunakan *Chi-Square*

K-Fold	Tahap Uji	Multinomial Naïve Bayes	
		Tanpa Chi-Square	Chi-Square dengan 400 fitur
2-fold	Tahap Uji 1	50%	60%
	Tahap Uji 2	49%	63%
5-fold	Tahap Uji 1	52%	73%
	Tahap Uji 2	53%	69%
	Tahap Uji 3	51%	71%
	Tahap Uji 4	54%	69%
10-fold	Tahap Uji 5	54%	65%
	Tahap Uji 1	55%	82%
	Tahap Uji 2	48%	70%
	Tahap Uji 3	50%	67%
	Tahap Uji 4	48%	68%
	Tahap Uji 5	54%	72%
	Tahap Uji 6	44%	71%
	Tahap Uji 7	49%	71%
	Tahap Uji 8	53%	69%
	Tahap Uji 9	54%	69%
Tahap Uji 10	49%	63%	

Sumber: Hasil Perhitungan

**B. Presisi**

**Tabel 4.** Tabel perbandingan presisi pada Metode *Multinomial Naïve Bayes* tanpa *Chi-Square* dengan Metode *Multinomial Naïve Bayes* menggunakan *Chi-Square*

K-Fold	Tahap Uji	Multinomial Naïve Bayes	
		Tanpa Chi-Square	Chi-Square dengan 400 fitur
2-fold	Tahap Uji 1	51%	67%
	Tahap Uji 2	50%	64%
5-fold	Tahap Uji 1	52%	75%
	Tahap Uji 2	53%	70%
	Tahap Uji 3	51%	73%
	Tahap Uji 4	54%	69%
	Tahap Uji 5	54%	67%
10-fold	Tahap Uji 1	55%	82%
	Tahap Uji 2	49%	73%
	Tahap Uji 3	50%	67%
	Tahap Uji 4	49%	70%
	Tahap Uji 5	55%	77%
	Tahap Uji 6	44%	71%
	Tahap Uji 7	48%	71%
	Tahap Uji 8	53%	68%

K-Fold	Tahap Uji	Multinomial Naïve Bayes	
		Tanpa Chi-Square	Chi-Square dengan 400 fitur
	Tahap Uji 9	54%	70%
Tahap Uji 10	50%	65%	

Sumber: Hasil Perhitungan

**C. Recall**

**Tabel 5.** Tabel perbandingan recall pada Metode *Multinomial Naïve Bayes* tanpa *Chi-Square* dengan Metode *Multinomial Naïve Bayes* menggunakan *Chi-Square*

K-Fold	Tahap Uji	Multinomial Naïve Bayes	
		Tanpa Chi-Square	Chi-Square dengan 400 fitur
2-fold	Tahap Uji 1	51%	61%
	Tahap Uji 2	50%	64%
5-fold	Tahap Uji 1	52%	73%
	Tahap Uji 2	53%	69%
	Tahap Uji 3	51%	71%
	Tahap Uji 4	54%	69%
10-fold	Tahap Uji 5	54%	65%
	Tahap Uji 1	55%	81%
	Tahap Uji 2	49%	72%
	Tahap Uji 3	50%	66%
	Tahap Uji 4	49%	69%
	Tahap Uji 5	55%	74%
	Tahap Uji 6	44%	70%
	Tahap Uji 7	48%	69%
	Tahap Uji 8	53%	67%
	Tahap Uji 9	53%	69%
Tahap Uji 10	50%	64%	

Sumber: Hasil Perhitungan

**D. F-Measure**

**Tabel 6.** Tabel perbandingan akurasi pada Metode *Multinomial Naïve Bayes* tanpa *Chi-Square* dengan Metode *Multinomial Naïve Bayes* menggunakan *Chi-Square*

K-Fold	Tahap Uji	Multinomial Naïve Bayes	
		Tanpa Chi-Square	Chi-Square dengan 400 fitur
2-fold	Tahap Uji 1	48%	57%
	Tahap Uji 2	49%	63%
5-fold	Tahap Uji 1	52%	73%
	Tahap Uji 2	52%	69%
	Tahap Uji 3	50%	70%
	Tahap Uji 4	54%	69%
	Tahap Uji 5	53%	64%
10-fold	Tahap Uji 1	55%	82%
	Tahap Uji 2	48%	70%
	Tahap Uji 3	50%	66%
	Tahap Uji 4	47%	68%
	Tahap Uji 5	54%	71%
	Tahap Uji 6	44%	71%
	Tahap Uji 7	48%	70%
	Tahap Uji 8	53%	68%
	Tahap Uji 9	53%	68%
	Tahap Uji 10	49%	63%

Sumber: Hasil Perhitungan

## 5. KESIMPULAN DAN SARAN

### A. KESIMPULAN

1. Pada penelitian ini performa akurasi tertinggi yang dihasilkan menggunakan *multinomial naïve bayes* yaitu sebesar 55% di tahap uji kesatu, dan performa presisi tertinggi yang dihasilkan yaitu sebesar 55% di tahap uji kesatu, dan performa recall tertinggi yang dihasilkan yaitu sebesar 55% di tahap uji kesatu, dan performa f-measure tertinggi yang dihasilkan yaitu sebesar 55% di tahap uji kesatu.
2. Pada penelitian ini performa akurasi tertinggi yang dihasilkan menggunakan *multinomial naïve bayes* dan *chi-square* dengan 400 fitur menghasilkan performa akurasi, presisi, *recall*, *f-measure* lebih tinggi dari pada menggunakan metode *multinomial naïve bayes* tanpa *chi-square* yaitu pada nilai performa akurasi dengan 10-fold di tahap uji kesatu sebesar 82%, nilai performa presisi dengan 10-fold di tahap uji kesatu sebesar 82%, nilai performa *recall* dengan 10-fold di tahap uji kesatu sebesar 81%, nilai performa *f-measure* 10-fold di tahap uji kesatu sebesar 82%.
3. Pada Penelitian ini seleksi fitur *chi-square* dapat meningkatkan akurasi, presisi, *recall* dan *f-measure*.

### B. SARAN

1. Pada penelitian berikutnya menggunakan data yang lebih dan terbaru untuk menyempurnakan model dan menambah data latih
2. Pada penelitian berikutnya dapat membandingkan dengan hasil metode klasifikasi dan seleksi fitur yang berbeda seperti seleksi fitur *Mutual Information* dan seleksi fitur *Information Gain*

## 6. DAFTAR PUSTAKA

- Agarwal, S., & Sureka, A. (2015). Topic-specific YouTube crawling to detect online radicalization. *Databases in Networked Information Systems: 10th International Workshop, DNIS 2015, Aizu-Wakamatsu, Japan, March 23-25, 2015. Proceedings 10*, 133–151.
- Ailiyya, S. (2020). *Analisis Sentimen Berbasis aspek Pada Ulasan Aplikasi Tokopedia Menggunakan Support Vector Machine*.
- Astari, Y., & Wahib Rozaqi, S. (2021). Analisis Sentimen Multi-Class pada Sosial Media menggunakan metode Long Short-Term Memory (LSTM). In *JLK* (Vol. 4, Issue 1).
- Dzulfaroh, A. N. (2022, May 31). *Ratusan CPNS Mengundurkan Diri, Apakah Jadi PNS Bukan Lagi Idaman*. <https://www.kompas.com/tren/read/2022/05/31/120000365/ratusan-cpns-mengundurkan-diri-apakah-jadi-pns-bukan-lagi-idaman?page=all>
- Hussein, D. M. E. D. M. (2018). A survey on sentiment analysis challenges. *Journal of King Saud University - Engineering Sciences*, 30(4), 330–338. <https://doi.org/10.1016/j.jksues.2016.04.002>
- Kamyab, M., Liu, G., & Adjeisah, M. (2021). Attention-based CNN and Bi-LSTM model based on TF-IDF and glove word embedding for sentiment analysis. *Applied Sciences*, 11(23), 11255.
- Kemp, S. (2022). *Digital 2022 : Indonesia*. <https://datareportal.com/reports/digital-2022-indonesia>
- Kencana, C. G., & Sibaroni, Y. (2019). Klasifikasi Sentiment Analysis pada Review Buku Novel Berbahasa Inggris dengan Menggunakan Metode Support Vector Machine (SVM). *EProceedings of Engineering*, 6(3).
- Kurniawan, T. (2017). Implementasi Text Mining Pada Analisis Sentimen Pengguna Twitter Terhadap Media Mainstream Menggunakan Naïve Bayes Classifier Dan Support Vector Machine. *Institut Teknologi Sepuluh Nopember*.

- Ling, J., Kencana, I., & Oka, T. B. (2014). Analisis Sentimen Menggunakan Metode Naïve Bayes Classifier Dengan Seleksi Fitur Chi Square. *E-Jurnal Matematika*, 3(3), 92–99.
- Manning, C. D. (2009). *An introduction to information retrieval*. Cambridge university press.
- Mayasari, L., & Indarti, D. (2022). Klasifikasi Topik Tweet Mengenai Covid Menggunakan Metode Multinomial Naive Bayes Dengan Pembobotan TF-IDF. *Jurnal Ilmiah Informatika Komputer*, 27(1), 43–53.
- Mishra, R. K., & Urolagin, S. (2019). A Sentiment analysis-based hotel recommendation using TF-IDF Approach. 2019 *International Conference on Computational Intelligence and Knowledge Economy (ICCIKE)*, 811–815.
- McCallum, A., & Nigam, K. (1998). A comparison of event models for naive bayes text classification. *AAAI-98 Workshop on Learning for Text Categorization*, 752(1), 41–48.
- Pradana, R. P., Arifianto, D., & Al Faruq, H. A. (2021). Sentiment Analysis Komentar Youtube Samsung S20 Menggunakan Metode Majority Vote Samsung S20 Youtube Comments Sentiment Analysis Using Majority Vote Method. *Jurnal Smart Teknologi*, 3(1), 12–21.
- Ramdani R Ananda Rizki, & Adisantoso, J. (2014). Documents Classification Using Rocchio Method With Feature Selection Using Chi-square. *Skripsi Mahasiswa Ekstensi*, 1(2).
- Ruli Siregar, R. A., Amelia Sinaga, F., Arianto, R., Studi Sarjana Teknik Informatika, P., & Tinggi Teknik PLN Jakarta Jalan Lingkar Luar Barat Menara PLN Cengkareng, S. (2017). Aplikasi Penentuan Dosen Penguji Skripsi Menggunakan Metode TF-IDF Dan Vector Space Model. In *Computatio: Journal of Computer Science and Information Systems* (Vol. 1, Issue 2).
- Setiawan, A., Fitri Astuti, I., & Harsa Kridalaksana, A. (2015). Klasifikasi Dan Pencarian Buku Refrenssi Akademik Menggunakan Metode Naive Bayes Classifier (NBC) (Studi Kasus : Perpustakaan Daerah Provinsi Kalimantan Timur). In *Jurnal Informatika Mulawarman* (Vol. 10, Issue 1).
- Setiawan, A. R., Rintyama, B. S., & Cahyanto, T. A. (2021). Preferensi Konsumen Terhadap Produk By. U Dan MPWR Dengan Analisis Sentimen Berbasis Multinomial Naïve Bayes Consumer Preferences On By. U And MPWR Products Using Sentimen Analysis Based On Multinomial Naïve Bayes. *Jurnal Smart Teknologi*, 3(1), 32–40.
- Sipayung, E. M., Maharani, H., & Zefanya, I. (2016). Perancangan Sistem Analisis Sentimen Komentar Pelanggan Menggunakan Metode Naive Bayes Classifier. *JSI: Jurnal Sistem Informasi (E-Journal)*, 8(1).
- Wirga, E. W. (2017). Analisis Konten Pada Media Sosial Video Youtube Untuk Mendukung Strategi Kampanye Politik. *Jurnal Ilmiah Informatika Komputer*, 21(1).
- Zaman, B., & Winarko, D. E. (2011). Analisis Fitur Kalimat untuk Peringkat Teks Otomatis pada Bahasa Indonesia. In *IJCCS* (Vol. 5, Issue 2).