

**Analisis Sentimen Masyarakat Terhadap Kinerja Presiden  
Indonesia Dalam Aspek Ekonomi, Kesehatan, dan Pembangunan  
Berdasarkan Opini dari Twitter**

**Tugas Akhir**  
**diajukan untuk memenuhi salah satu syarat**  
**memperoleh gelar sarjana**  
**dari Program Studi Informatika**  
**Fakultas Informatika**  
**Universitas Telkom**

**1301154516**  
**Widya Pratiwi Ali**



**Program Studi Sarjana Informatika**  
**Fakultas Informatika**  
**Universitas Telkom**  
**Bandung**  
**2019**

## Analisis Sentimen Masyarakat Terhadap Kinerja Presiden Indonesia Dalam Aspek Ekonomi, Kesehatan, Pembangunan Berdasarkan Opini dari Twitter

Widya Pratiwi Ali<sup>1</sup>, Yuliant Sibaroni, S.Si., M.T.<sup>2</sup>

<sup>1,2</sup>Fakultas Informatika, Universitas Telkom, Bandung

<sup>1</sup>widyaprtw@students.telkomuniversity.ac.id, <sup>2</sup>yuliant@telkomuniversity.ac.id

---

### Abstrak

Menjelang pilpres tahun 2019, opini – opini atau *tweet* yang berkaitan dengan Presiden dan Calon Presiden adalah yang paling banyak diutarakan oleh pengguna *twitter* di Indonesia saat ini. Opini – opini masyarakat sangat penting untuk mengetahui keadaan keberpihakan masyarakat pada pemilihan presiden yang akan datang. Selain itu dengan melihat opini – opini yang terpampang secara bebas di *twitter*, kita dapat mengetahui secara umum keadaan beberapa aspek ekonomi, aspek kesehatan, dan aspek pembangunan dengan memanfaatkan opini – opini di *twitter*. Pada Tugas Akhir ini dibangun sistem untuk analisis sentimen dalam tiga aspek yaitu ekonomi, kesehatan, dan pembangunan yang berupa sentimen positif atau sentimen negatif. Metode yang digunakan adalah *Naïve Bayes* dengan menggunakan ekstraksi fitur *Lexicon SentiWordnet* dan penggabungan *TF-IDF* dengan *Lexicon SentiWordnet*. Masukan dari sistem ini berupa dataset *tweet* dari *Twitter* sebanyak 1357, kemudian dataset tersebut dilabeli secara manual. Keluaran dari penelitian ini berupa evaluasi dengan menggunakan *10 fold cross validation*, kemudian pengukuran akurasi diukur dengan *confusion matrix*. Berdasarkan hasil penelitian yang telah dilakukan, penggunaan *Naïve Bayes* dengan ekstraksi fitur *Lexicon SentiWordnet* dalam pembuatan sistem *Sentiment Analysis* terbukti lebih baik dengan akurasi 84,75% dibandingkan dengan *Naïve Bayes* dengan menggunakan ekstraksi fitur *TF-IDF* ataupun *TF-IDF* yang digabungkan dengan *Lexicon SentiWordnet*.

**Kata kunci :** *Naïve Bayes, Lexicon SentiWordnet, Twitter, confusion matrix, analisis sentimen, TF-IDF*

---

### Abstract

Towards the 2019 presidential election, opinions or tweets related to the President and Presidential Candidates are the most widely expressed by twitter users in Indonesia today. Public opinion is very important to understand the state of community alignments in the upcoming Presidential election. In addition, by looking at opinions posted on Twitter, we can discuss several aspects of the economy, health aspects, and aspects of infrastructure by using opinions on Twitter. In this Final Project a system for sentiment analysis is built in three aspects, namely economic, health, and development which contain positive sentiments or negative sentiments. The method that used is *Naïve Bayes* by using the *Lexicon SentiWordnet* for the feature extraction and the integration of *TF-IDF* with *Lexicon SentiWordnet*. Issued from this system consists of tweet datasets from Twitter totaling 1357, then the dataset is labeled manually. The output of this study consisted of evaluations using a *10-fold cross validation*, then the evaluation was completed with a *confusion matrix*. Based on the results of research that has been done, the use of *Naïve Bayes* with the extraction of the *Lexicon SentiWordnet* feature in making *Sentiment Analysis* systems proved to be better with 84.75% consultation compared to *Naïve Bayes* by using the *TF-IDF* or *TF-IDF* feature extraction combined with the *Lexicon SentiWordnet*.

**Keywords:** *Naïve Bayes, Lexicon SentiWordnet, Twitter, confusion matrix, sentiment analysis, TF-IDF*

---

## 1. Pendahuluan

### Latar Belakang

Indonesia merupakan salah satu negara yang menganut sistem hukum demokrasi. Sistem demokrasi dibentuk agar masyarakat dapat berpartisipasi langsung untuk memilih kebijakan politik yakni menyuarakan pendapat yang nantinya dipakai untuk menentukan suatu keputusan. Pemilu adalah salah satu wujud dari sistem demokrasi ini. Sebelum teknologi berkembang dengan sangat pesat, masyarakat menyampaikan opini maupun kritik melalui media cetak sehingga para peneliti mengamati artikel-artikel yang dibuat oleh beberapa orang[1]. Hal ini berjalan dengan sangat baik karena pada masa tersebut media cetak memang merupakan salah satu media yang paling banyak digunakan oleh masyarakat untuk mendapatkan berbagai macam informasi secara detail. Seiring dengan perkembangan teknologi yang begitu pesat, media cetak sedikit demi sedikit mulai tersingkirkan.

Berbagai macam media sosial bermunculan salah satunya yaitu twitter. Masyarakat tidak lagi membutuhkan media cetak untuk mengutarakan opini dan kritiknya secara panjang lebar. *Twitter* adalah sebuah media atau jaringan informasi yang diluncurkan pada tahun 2006. Masyarakat dapat mengungkapkan apa saja yang ingin disampaikan secara bebas dengan batasan 280 karakter pada setiap *tweet*. Karena kebebasan dalam menyampaikan pendapat terbuka luas, informasi informasi terbaru bisa dengan sangat cepat untuk didapatkan. Berdasarkan data dari Statista[2], pada tahun 2018 pengguna *twitter* telah mencapai 350 juta orang dan terdapat 500 juta *tweet* setiap harinya. Maka dari itu, *twitter* merupakan wadah yang paling baik untuk pengambilan data dalam menganalisis sentimen masyarakat secara luas.

Menjelang pilpres tahun 2019, opini – opini atau *tweet* yang berkaitan dengan Presiden dan Calon Presiden adalah yang paling banyak diutarakan oleh pengguna *twitter* di Indonesia saat ini. Opini – opini masyarakat sangat penting untuk mengetahui keadaan keberpihakan masyarakat pada pemilihan presiden yang akan datang. Selain itu dengan melihat opini – opini yang terpampang secara bebas di *twitter*, kita dapat mengetahui secara umum keadaan beberapa aspek ekonomi, aspek kesehatan, dan aspek pembangunan dengan memanfaatkan opini – opini di *twitter* menggunakan metode *Naive Bayes Classifier* yang dikombinasikan dengan ekstraksi fitur *Lexicon SentiWordnet*.

Analisis sentimen masyarakat yang diklasifikasikan dalam beberapa aspek tersebut bermanfaat untuk mengetahui sejauh mana kinerja yang telah dilakukan oleh Presiden. Atas dasar ini, penulis bermaksud untuk melakukan analisis sentimen masyarakat dan mengklasifikasikannya kedalam aspek ekonomi, kesehatan, dan pembangunan. Sentimen masyarakat berkaitan dengan kinerja sangat penting untuk diketahui oleh seorang Presiden agar mengetahui tingkat kepuasan rakyatnya. Penelitian mengenai analisis sentimen telah banyak dilakukan sebelumnya dengan berbagai macam metode. Bahkan pada saat pemilihan Gubernur DKI Jakarta tahun 2017 juga telah dilakukan analisis sentimen oleh Buntoro[3]. Pada penelitian tersebut, mereka menggunakan kombinasi dari *Lexicon based* dengan *Naive Bayes* dan *Support Vector Machine* dan menyatakan bahwa *Lexicon Based* dapat mempengaruhi tingkat akurasi dari suatu program. Namun pada penelitian tersebut, Buntoro dan kawan - kawan hanya mengklasifikasikan dataset sebanyak 300 *tweet* terhadap dua kelas saja yaitu positif dan negatif dan mendapatkan akurasi sebesar 95% untuk metode *Naive Bayes*. Penelitian selanjutnya yang menggunakan *Lexicon based* yaitu Jea [4], Jea menggunakan *Lexicon Based* dalam tahapan ekstraksi fitur pada penelitiannya. *Dataset* yang digunakan yaitu *dataset* Bahasa Inggris dan metode klasifikasi yang digunakan yaitu *Support Vector Machine*.

Berdasarkan latar belakang yang sudah diuraikan, sistem ini dibuat dengan menerapkan metode *Naive Bayes* dalam mengklasifikasikan dataset *tweet* atau opini sebanyak 1508 data yang diambil dari *twitter* dan menggunakan *Lexicon SentiWordnet* untuk proses ekstraksi fitur. Penulis juga mencoba membandingkan hasil dari ekstraksi fitur *TF-IDF* dan menggabungkan *TF-IDF* dengan *Lexicon SentiWordnet*.

Tujuan dari penelitian ini adalah untuk mengetahui pengaruh penggunaan *Lexicon SentiWordnet* dalam tahap ekstraksi fitur yang kemudian akan di klasifikasi oleh metode *Naive Bayes* terhadap performansi sistem. Selanjutnya yaitu mengetahui pengaruh jika metode ekstraksi fitur dengan *TF-IDF* digabungkan dengan *Lexicon SentiWordnet*. Dan yang terakhir yaitu mengetahui tingkat kepuasan masyarakat terhadap kinerja Presiden dalam aspek ekonomi, kesehatan, dan pembangunan berdasarkan hasil klasifikasi oleh sistem.

## 2. Studi Terkait

Analisis sentimen merupakan bidang studi yang menganalisis pendapat, sentimen, evaluasi, sikap dan emosi terhadap suatu entitas seperti produk, jasa, organisasi, individu, masalah, topik dan atribut dari entitas tersebut. Terdapat berbagai sebutan dari analisis sentimen ini, antara lain adalah sentimenon mining, sentimen on extraction, sentimen mining, subjectivity analysis, affect analysis, emotion analysis, review mining dan sebagainya[5].

Analisis sentimen beberapa tahun terakhir ini telah banyak dilakukan oleh banyak peneliti. Selain untuk memprediksi tingkat keberpihakan masyarakat terhadap kandidat calon kepala daerah, analisis sentimen juga banyak dilakukan untuk mengetahui kepuasan masyarakat terhadap suatu sistem maupun produk, misalnya pada produk dari Amazon[6]. Data – data untuk menganalisis sentimen masyarakat ini dapat diambil dari berbagai macam sosial media, namun sebagian besar peneliti mengambil data-data dari *twitter*.

*Twitter* adalah salah satu layanan jejaring sosial yang sampai saat ini banyak digunakan oleh masyarakat untuk mengirim dan membaca pesan, baik itu mengenai hal pribadi, politik, maupun fenomena – fenomena yang sedang terjadi. Masyarakat dapat menyampaikan pesannya dengan dibatasi 280 karakter pada setiap *tweet* yang dikirimkan. Berdasarkan data dari Statista yang telah disampaikan pada bab sebelumnya, pengguna *Twitter* di tahun 2018 telah mencapai 350.000.000 yang tersebar di seluruh dunia dan terdapat 500.000.000 *tweet* setiap harinya. Fitur yang disediakan oleh *twitter* antara lain adalah *Home*, *Profil*, *Notifications*, *Mentions*, *Following*, *Followers*, *Direct Message*, *Hastag*, *Trending Topic* dan sebagainya.

*Twitter* merupakan media sosial yang berkembang dengan sangat pesat dan memiliki karakteristik dimana penggunaannya dapat mengirimkan opini secara bebas, membaca topik terkini, mengupdate kembali (*retweet*),

maupun mengomentari[7]. Dengan fitur - fitur tersebut masyarakat dapat mengekspresikan secara langsung apa yang mereka sukai dan yang tidak mereka sukai secara umum sehingga memudahkan para peneliti untuk melakukan analisis sentimen. Karena karakteristik tersebut media sosial Twitter merupakan sarana yang paling baik untuk menganalisis sentimen masyarakat dengan menerapkan metode *Machine Learning*.

Analisis sentimen masyarakat terhadap kepala daerah dan calon kepala daerah sudah dilakukan oleh beberapa peneliti. Terdapat metode yang berbeda-beda yang diterapkan dalam menganalisis sentimen pada twitter yang dilakukan oleh peneliti. Analisis sentimen masyarakat pada twitter dengan metode *Naive Bayes* dan *Lexicon* sebelumnya telah dilakukan oleh Joyce dan Jang [8]. Mereka melakukan analisis sentimen masyarakat terhadap Calon Presiden Amerika Serikat yaitu Trump dan Clinton pada twitter seratus hari sebelum pemilihan umum. Joyce dan Jang mendapatkan hasil akurasi yang lebih baik saat menggunakan metode *Lexicon* dibandingkan dengan *Naive Bayes*.

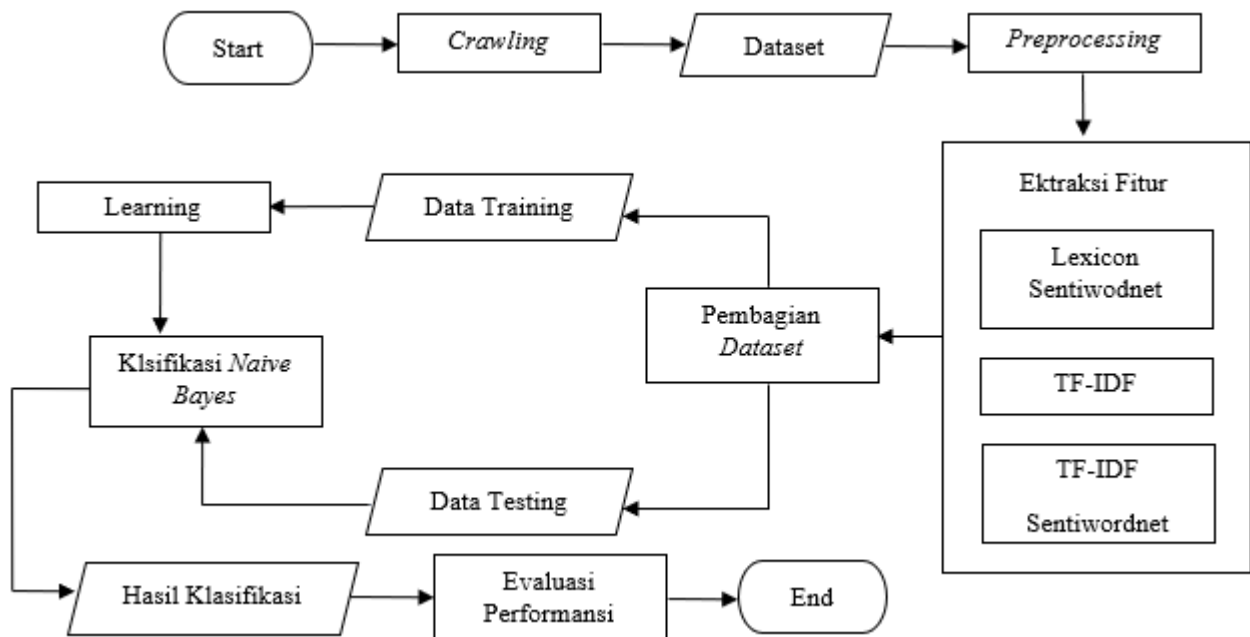
Penelitian mengenai sentimen masyarakat di Twitter terhadap Calon Presiden juga dilakukan oleh Ghulam, dkk[9]. Ketiga peneliti ini mengklasifikasikan tweet pada twitter menjadi lima kelas yaitu sangat positif, positif, netral, negatif, sangat negatif. Proses klasifikasi menggunakan metode *Naive Bayes* dimana data processingnya menggunakan *tokenization*, *cleansing*, dan *filtering*. Hasil akurasi yang didapatkan dengan *Naive Bayes* yaitu 71,88%, *precision* 71,6% , *recall* 71,9%, 6,1% *TP rate* dan 65% *TN rate*.

Selain metode *Lexicon* dan *Naive Bayes*, metode yang sering digunakan oleh peneliti yaitu metode *Support Vector Machine* dan *Maximum Entropy*. Peneliti yaitu Parul dan Teng Sheng [10] menggunakan metode *SVM* dalam menganalisis sentimen masyarakat di twitter terhadap pemilihan umum tahun 2016 di India. Parul dan Teng Sheng dalam penelitiannya menggunakan 42,235 tweet dalam Bahasa India atau *Hindi Language* untuk memprediksi kemenangan dari calon bernama Barathiya Janata Party. Penelitian ini memprediksikan kemenangan calon tersebut dengan menghasilkan akurasi 78,4% dengan metode *SVM*.

### 3. Sistem yang Dibangun

#### 3.1 Gambaran Umum Sistem

Pada tugas akhir ini penulis membangun sebuah sistem yang mampu menganalisis sentimen masyarakat pada twitter dengan mengkombinasikan ekstraksi fitur *Lexicon SentiWordnet* dan *Naive Bayes*, *TF-IDF* dan *Naive Bayes*, dan yang terakhir penggabungan *TF-IDF* dan *Lexicon SentiWordnet* lalu diklasifikasikan oleh *Naive Bayes*. Proses pada penelitian analisis sentimen ini dimulai dengan pengumpulan dataset dengan teknik crawling data yang berupa opini masyarakat pada twitter, pelabelan dataset secara manual, *preprocessing* pada dataset, ekstraksi fitur, lalu klasifikasi menggunakan metode *Naive Bayes* dan menggunakan *k-fold cross validation*. Proses penelitian ini digambarkan pada Gambar 1.



Gambar 1. Gambaran Umum Sistem

#### 3.2 Dataset

Data yang digunakan dalam penulisan tugas akhir ini merupakan *dataset tweet* dari pengguna *twitter*

dengan cara *crawling data* menggunakan *twitterscraper*. Data diambil dengan cara memasukkan kata – kata kunci tertentu yaitu sebagai berikut:

**Table 1. Contoh kata kunci**

Kategori	Kata Kunci
Ekonomi	rupiah, impor, miskin, sembako, ekonomi
Kesehatan	bpjs, rumah sakit, berobat, kesehatan mahal, kesehatan terjamin
Pembangunan	infrastruktur, pembangunan, irigasi, jalan, tol

Data yang berhasil didapatkan dari proses *crawling* adalah berjumlah sekitar 50.000 data, namun dataset yang digunakan hanya 1508. Pengurangan dataset dilakukan karena keterbatasan kemampuan manusia yang melakukan pelabelan. Pelabelan yang dilakukan adalah secara manual. Banyaknya data yang akan dilabeli akan membutuhkan banyak waktu. Dataset ini dikumpulkan dari proses *crawling* pada setiap kata kunci dengan memasukkan waktu yang spesifik. Dataset yang diambil juga hanya berupa opini dan menghilangkan data – data yang berisi fakta maupun iklan.

### 3.3 Pelabelan

Pelabelan dataset dilakukan secara manual dengan harapan menghasilkan ketepatan atau akurasi yang baik dalam pelabelan. Pelabelan dilakukan oleh tiga orang agar menghindari data yang tidak akurat dikarenakan keterbatasan pengetahuan oleh pemberi label. Pelabelan data dibagi menjadi enam kategori yaitu ekonomi positif, ekonomi negatif, kesehatan positif, kesehatan negatif, pembangunan positif, dan pembangunan negatif. Pada sistem data tersebut dilabeli dengan angka 0-5.

### 3.4 Preprocessing

Setelah dataset yang sudah dilabeli, tahap selanjutnya adalah *preprocessing*. *Preprocessing* merupakan tahap untuk mengolah dataset menjadi data yang berkualitas. Tahap *preprocessing* yang digunakan pada penelitian ini adalah *tokenization*, *case folding*, *remove punctuation*, *stopword removal*, *non-standard word handling*, dan *stemming*. Penggunaan *non-standard word handling* pada penelitian ini mampu meningkatkan performansi sistem dibandingkan hanya menggunakan *stemming*. Ilustrasi *preprocessing* dapat dilihat pada Tabel 3.1.

**Table 2. Ilustrasi *praprocessing***

No.	Proses	Deskripsi	Input	Output
1.	<i>Tokenization</i>	Proses pemisahan atau pemotongan setiap kata yang menyusun suatu dokumen.	Sepakat, di papua harga sembako bs setara dgn di jawa itu krn infrastruktur	Sepakat,   di   papua   harga   sembako   bs   setara   dgn   di   jawa   itu   krn   infrastruktur
2.	<i>Case Folding</i>	Pada tahap ini, seluruh data yang berupa tweet akan diubah menjadi huruf kecil atau non-kapital.	Sepakat, di papua harga sembako bs setara dgn di jawa itu krn infrastruktur	Sepakat, di papua harga sembako bs setara dgn di jawa itu krn infrastruktur
3.	<i>Remove Punctuation</i>	Proses penghapusan tanda baca, simbol, karakter, dan URL.	Sepakat, di papua harga sembako bs setara dgn di jawa itu krn infrastruktur	Sepakat di papua harga sembako bs setara dgn di jawa itu krn infrastruktur
4.	<i>Stopword Removal</i>	Proses penghapusan kata yang dianggap tidak memiliki arti. Hal ini disesuaikan dengan keinginan peneliti.	Sepakat, di papua harga sembako bs setara dgn di jawa itu krn infrastruktur	Sepakat papua harga sembako bs setara dgn jawa krn infrastruktur

5.	<i>Non Standard Word Handling</i>	Proses mengubah kata – kata informal menjadi kata formal dengan menggunakan kamus kata yang dibuat sendiri.	Sepakat papua harga sembako bs setara dgn jawa krn infrstruktur.	Sepakat papua harga sembako bisa setara dengan jawa karena infrstruktur
6.	<i>Stemming</i>	Proses pemotongan kata – kata yang mengandung imbuhan menjadi kata dasar. Pada tahap ini, penulis menggunakan algoritma nazief dan andriani [11]	Sepakat papua harga sembako bisa setara dgn jawa karena infrstruktur	Sepakat papua harga mbako bisa tara dgn jawa karena infrastruktur

### 3.5 Ekstraksi Fitur

Tahap ekstraksi fitur pada penelitian ini dibagi menjadi tiga bagian yaitu ekstraksi fitur dengan metode *TF-IDF*, *Lexicon Sentiwordnet*, dan yang terakhir yaitu *TF-IDF* yang digabungkan dengan *SentiWordnet*.

#### TF-IDF

*TF* adalah frekuensi kemunculan *term* pada dataset dan *IDF* adalah sebuah pembobotan bagaimana *term* itu didistribusikan secara luas pada seluruh *dataset* yang bersangkutan. Semakin sedikit jumlah data yang mengandung *term* yang dimaksud, maka semakin besar nilai *IDF*nya [12]. Berikut ini penggunaan *TF-IDF* pada penelitian ini.

$$IDF_i = \log_2(D / D f_j)$$

$IDF_i$  = bobot *IDF term i*  
 $D$  = jumlah semua data tweet yang ada dalam database  
 $DF_i$  = jumlah dokumen yang mengandung *term i*.

Perhitungan *IDF* diatas selanjutnya dipadukan dengan pembobotan kata *TF* sehingga menjadi metode *TF-IDF*. Persamaan yang digunakan untuk menghitung pembobotan *TF-IDF* dari suatu *term* adalah sebagai berikut:

$$W_{ij} = \frac{TF_{ij}}{K_j} \cdot IDF \quad (1)$$

$$W_{ij} = \frac{TF_{ij}}{K_j} \cdot \log_2 \frac{D}{DF} \quad (2)$$

Keterangan:

$W_{ij}$  = bobot *term i* terhadap data *j*

$K_j$  = jumlah semua *term* yang ada pada data *j*

$TF_j$  = bobot *term i* terhadap data *j*

Table 3. Contoh Dokumen untuk *TF-IDF*

ID	Teks
D1	sembako murah rakyat sejahtera
D2	sembako impor petani susah
D3	bangun infrastruktur rakyat sejahtera
D4	infrastruktur tidak penting
D5	sehat mahal tutup bpjs
D6	obat bpjs gratis

Table 4. Skenario Pembobotan *TF-IDF*

Term	TF							IDF	$\frac{TF_{ij}}{K_j} . IDF$					
	D 1	D 2	D 3	D 4	D 5	D 6	DF	$\log_2 (D / Df_{ij})$	D1	D2	D3	D4	D5	D6
sembako	1	1	0	0	0	0	2	0,477	0,477	0,477	0	0	0	0
murah	1	0	0	0	0	0	1	0,778	0,778	0	0	0	0	0
rakyat	1	0	1	0	0	0	2	0,477	0,477	0	0,477	0	0	0
sejahtera	1	0	1	0	0	0	2	0,477	0,477	0	0,477	0	0	0
impor	0	1	0	0	0	0	1	0,778	0	0,778	0	0	0	0
petani	0	1	0	0	0	0	1	0,778	0	0,778	0	0	0	0
bangun	0	1	0	0	0	0	1	0,778	0	0,778	0	0	0	0
infrastruktur	0	0	1	1	0	0	2	0,477	0	0	0,477	0,477	0	0
tidak	0	0	0	1	0	0	1	0,778	0	0	0	0,778	0	0
penting	0	0	0	1	0	0	1	0,778	0	0	0	0,778	0	0
sehat	0	0	0	0	1	0	1	0,778	0	0	0	0	0,778	0
mahal	0	0	0	0	1	0	1	0,778	0	0	0	0	0,778	0

### Lexicon SentiWordnet

Terdapat beberapa model *lexicon*, namun yang digunakan pada penelitian ini adalah *SentiWordNet*. Saat menentukan klasifikasi sentimen, skor polaritas suatu kata opini akan bernilai 1 jika kata tersebut adalah kata opini positif, dan bernilai -1 jika kata tersebut adalah kata opini negatif [3]. Pada penelitian ini penulis menyiapkan kamus untuk masing masing sentimen negatif dan sentimen positif. Contoh kamus adalah sebagai berikut

Berikut ini adalah contoh ilustrasi dari *SentiWordnet* dengan menggunakan dokumen 2 dan dokumen 3 dari proses *TF-IDF* [13] :

Table 5. Kamus untuk pembobotan *SentiWordnet*

No.	Kategori	Keywords
1	Positif	Alhamdulillah, bahagia, baik, cepat, cermat, damai, giat, gesit, infrastruktur, makmur, sejahterah
2	Negatif	Miskin, pengangguran, tekor, tidak, ugal-ugalan, takut, licik.

Table 6. Ilustrasi pembobotan *SentiWordnet*

	bangun	infrastruktur	rakyat	sejahtera
D1	1	1	0	1
	sehat	Mahal	tutup	bpjs
D2	1	-1	-1	0

### SentiWordNet x *TF-IDF*

Dari penguraian tentang *TF-IDF* dan *SentiWordnet*, dapat dilihat bahwa *TF-IDF* dan *SentiWordnet* memiliki tipe data yang sama pada sistem. Maka dari itu, pada tahap ini penulis menggabungkan *SentiWordnet* dengan *TF-IDF* dengan mengalikan masing masing nilai term pada tiap dokumen untuk mendapatkan bobot dari tiap term.

Berikut ini adalah ilustrasi dari penggabungan *TF-IDF* dan *SentiWordnet*:

Table 7. Ilustrasi Penggabungan *TF-IDF* dan *SentiWordnet*

	bangun	infrastruktur	rakyat	sejahtera

D1 <i>SentiWordnet</i>	1	1	0	1
D1 <i>TF-IDF</i>	0,778	0,477	0,477	0,477
<i>SWN x TF-IDF</i>	0,778	0,477	0	0,477
	sehat	mahal	tutup	bpjs
D2 <i>SentiWordnet</i>	1	-1	-1	0
D2 <i>TF-IDF</i>	0,778	0,778	0,778	0,778
<i>SWN x TF-IDF</i>	0,778	-0,778	-0,778	0

### 3.6 Klasifikasi

#### *Naïve Bayes*

Setelah melakukan pembobotan pada tahap ekstraksi fitur, selanjutnya dilakukan pembangunan sistem klasifikasi sentimen dengan metode *Naïve Bayes*. *Naïve Bayes* merupakan metode *classifier* berdasarkan probabilitas dan *Teorema Bayesian* dengan asumsi bahwa setiap variabel X bersifat bebas (*independence*). Pembangunan model *classification* didapat dengan melakukan perhitungan *prior* dan *conditional/likelihood probability* dengan menggunakan data training. Nilai probabilitas posterior terbesar yang akan menjadi kelas dari suatu dokumen. Nilai *Maximum posterior* terhadap suatu kelas dapat dihitung menggunakan rumus pada persamaan (3)[14].

$$C_{MAP} = \underset{c \in C}{\operatorname{argmax}} P(c|d) = \underset{c \in C}{\operatorname{argmax}} P(c) \prod_{i=1}^n P(w_i|c) \quad (3)$$

Keterangan:

$C_{MAP}$  : *Maximum A Posteriori* yaitu peluang tertinggi pada setiap kelas

$P(c|d)$  : *Probability* kelas c bersyarat d

$P(w_i|c)$  : *Probability* kemunculan sebuah kata ( $w_i$ ) dalam dokumen pada kelas (c).

$P(c)$  : *Prior Probability* dari dokumen yang muncul pada kelas c

Perhitungan nilai  $P(c)$  dan  $P(w_i|c)$  dapat dilakukan saat membangun model *classifier*. Perhitungan nilai *prior probability*  $P(c)$  dapat dilakukan dengan menggunakan persamaan (4)

$$P_c = \frac{N_c}{N} \quad (4)$$

Dimana  $N_c$  merupakan jumlah dokumen yang merupakan kelas c dan N merupakan jumlah dokumen pada data latih. Untuk perhitungan *conditional probability* dilakukan dengan menggunakan persamaan (5):

$$P(w|c) = \frac{\operatorname{count}(w_i,c)+1}{\operatorname{count}(c)+|v|} \quad (5)$$

Dimana  $\operatorname{count}(w|c)$  merupakan jumlah kata yang diamati pada kelas c,  $\operatorname{count}(c)$  merupakan jumlah seluruh kata yang ada pada kelas c dan  $|v|$  merupakan jumlah kata unik yang terdapat pada data latih.

Berikut ini perhitungan *Naïve Bayes* yang digunakan pada penelitian ini berdasarkan contoh data latih pada tabel 8.



Table 8. Contoh data latih

ID	Fitur	Kelas	Kategori
D1	sembako murah rakyat sejahtera	Positif	Ekonomi
D2	sembako impor petani susah	Negatif	Ekonomi
D3	bangun infrastruktur rakyat sejahterah	Positif	Pembangunan
D4	infrastruktur tidak penting	Negatif	Pembangunan
D5	sehat mahal tutup bpjs	Negatif	Kesehatan
D6	Obat bpjs gratis	Positif	Kesehatan
D7	Sembako mahal rakyat susah	?	?

- Langkah pertama yaitu menghitung nilai *prior probability* untuk masing – masing kelas sentimen dan kategori menggunakan persamaan (4):  

$$P(\text{Positif}) = 3/6 \quad P(\text{Negatif}) = 3/6$$

$$P(\text{Ekonomi}) = 2/6 \quad P(\text{Pembangunan}) = 2/6 \quad P(\text{Kesehatan}) = 2/6$$
- Langkah kedua yaitu melakukan perhitungan *conditional probability* untuk masing-masing kata pada data latih berdasarkan kelas sentimen dan kategori menggunakan persamaan (5):  

$$P(\text{sembako, pos}) = 0,076 \quad P(\text{mahal, pos}) = 0,038 \quad P(\text{rakyat, pos}) = 0,076 \quad P(\text{susah, pos}) = 0,038$$

$$P(\text{sembako, neg}) = 0,074 \quad P(\text{mahal, neg}) = 0,074 \quad P(\text{rakyat, neg}) = 0,037 \quad P(\text{susah, neg}) = 0,074$$

$$P(\text{sembako, eko}) = 0,12 \quad P(\text{mahal, eko}) = 0,04 \quad P(\text{rakyat, eko}) = 0,08 \quad P(\text{susah, eko}) = 0,08$$

$$P(\text{sembako, pem}) = 0,043 \quad P(\text{mahal, pem}) = 0,043 \quad P(\text{rakyat, pem}) = 0,086 \quad P(\text{susah, pem}) = 0,043$$

$$P(\text{sembako, kes}) = 0,043 \quad P(\text{mahal, kes}) = 0,086 \quad P(\text{rakyat, kes}) = 0,043 \quad P(\text{susah, kes}) = 0,043$$
- Langkah ketiga yaitu menghitung nilai *posterior probability* untuk masing-masing kelas sentimen dan kategori untuk mengetahui kelas dokumen 4 menggunakan persamaan (3):  

$$P(\text{Positif|d4}) = 0,5 \times 0,076 \times 0,038 \times 0,076 \times 0,038 = 0,000004377$$

$$P(\text{Negatif|d4}) = 0,5 \times 0,074 \times 0,074 \times 0,037 \times 0,074 = 0,000007527$$

$$P(\text{Ekonomi|d4}) = 0,333 \times 0,12 \times 0,04 \times 0,08 \times 0,08 = 0,0000102$$

$$P(\text{Kesehatan|d4}) = 0,333 \times 0,043 \times 0,043 \times 0,086 \times 0,043 = 0,00000238$$

$$P(\text{Pembangunan|d4}) = 0,333 \times 0,043 \times 0,086 \times 0,043 \times 0,043 = 0,00000238$$

Dari hasil perhitungan diatas, maka hasil klasifikasi dokumen 7 adalah Ekonomi Negatif, karena memiliki nilai *posterior probability* tertinggi yaitu pada kelas negatif 0,000007527 dan pada kategori ekonomi yaitu 0,0000102.

### 3.7 Evaluasi

Pada tahap evaluasi dilakukan pengujian sistem untuk mengetahui performansi dari hasil klasifikasi yang telah dibuat dengan menghitung nilai *accuracy*, *precision*, *recall*, dan *f-measure*. Evaluasi performansi merupakan salah satu parameter yang digunakan untuk mengukur seberapa akurat suatu metode yang di implementasikan. Pengembangan sistem dalam evaluasi ini menggunakan *confusion matrix*. Gambaran mengenai *confusion matrix* dapat dilihat pada Tabel 9.

Table 9. Tabel Confussion Matrix

	<i>Actual positive</i>	<i>Actual negative</i>
<i>Predicted positive</i>	TP	FP
<i>Predicted negative</i>	FN	TN

Keterangan tabel adalah sebagai berikut :

- 1) TP yaitu *true positive*, artinya sistem memprediksi positif dan nilai kelas sebenarnya juga positif
- 2) TN yaitu *true negative*, artinya sistem memprediksi negatif dan nilai kelas sebenarnya juga negatif.
- 3) FP yaitu *false positive*, artinya sistem memprediksi positif namun nilai kelas sebenarnya adalah negatif.
- 4) FN yaitu *false negative*, artinya sistem memprediksi negatif namun nilai kelas sebenarnya adalah positif.

Pada tugas akhir ini dilakukan pengukuran performansi menggunakan akurasi. Rumus akurasi dapat dilihat pada rumus (6).

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad Precision = \frac{TP}{TP+FP}$$

$$Recall = \frac{TP}{TP+FN} \quad F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (6)$$

Evaluasi dilakukan untuk mengetahui apakah sistem yang dibuat telah bagus atau tidak. Pengujian sistem ini dilakukan dengan *Confussion Matrix* yaitu *true positive rate (TP rate)*, *true negative (TN rate)*, *false positive rate (FP rate)* dan *false negative rate (FN rate)* sebagai indikator. *TP rate* adalah presentase dari kelas positif yang berhasil diklasifikasikan sebagai kelas positif, sedangkan *TN rate* adalah presentase dari kelas negatif yang berhasil diklasifikasikan sebagai kelas negatif. *FP rate* adalah kelas negatif yang diklasifikasikan sebagai kelas positif. *FN rate* adalah kelas positif yang diklasifikasikan sebagai kelas negatif [12].

### 3.7.1 K-Folds Cross Validation

*K-fold Cross Validation* merupakan salah satu metode yang digunakan untuk mengetahui rata – rata keberhasilan dari suatu sistem dengan cara melakukan perulangan dengan mengacak atribut masukan sehingga sistem tersebut teruji untuk beberapa atribut input yang acak[15]. Model yang telah dibangun akan di latih menggunakan data *training* dan di uji menggunakan data *testing*. Jenis *Cross Validation* yang digunakan pada tugas akhir ini adalah *10-Folds Cross Validation* secara *default* dengan menggunakan perbandingan data *training* dengan data *testing* sebesar 90 : 10. Metode ini digunakan dalam memvalidasi jumlah data training dan data testing untuk menentukan hasil *precision*, *recall*, dan *f-measure* yang terbaik dari semua *fold* yang dilakukan [16]

Pada tugas akhir ini terdapat sebanyak 1508 tweet yang dibagi masing – masing 1357 untuk data *training* yang dibulatkan kebawah, dan 151 data testing yang dibulatkan keatas dari hasil perbandingan 90 : 10.

## 4. Evaluasi

### 4.1 Skenario

Proses klasifikasi dengan menerapkan metode *Naïve Bayes* dilakukan untuk mengetahui opini masyarakat di twitter terhadap kinerja presiden yang bernilai negatif atau positif pada masing masing aspek yaitu aspek ekonomi, aspek kesehatan, dan aspek pembangunan. Agar tercapai hasil yang optimal, pada penelitian ini dibangun skenario pengujian dalam menghasilkan performa klasifikasi untuk dijadikan perbandingan. Skenario pengujian dapat dilihat pada Tabel 8.


**Table 10. Skenario Pengujian**

No.	Skenario	Tujuan
1.	Membandingkan pengaruh penggunaan non-standard word handling pada <i>preprocessing</i> .	Mengetahui pengaruh tahap preprocessing yang menggunakan <i>non-standard word handling</i> dan tanpa menggunakan <i>non-standard word handling</i> terhadap performansi sistem.
2.	Membandingkan hasil akurasi penggunaan ekstraksi fitur TF-IDF, SentiWordnet, TF-IDF x SentiWordnet	Mengetahui akurasi dari penggunaan masing – masing ekstraksi fitur dan penggunaan klasifikasi yang memiliki hasil yang terbaik.
3.	Menentukan presentase kinerja presiden dalam aspek ekonomi, kesehatan, pendidikan berdasarkan hasil klasifikasi.	Mengetahui tingkat kepuasan masyarakat berdasarkan dari hasil klasifikasi sentimen.

### 4.2 Hasil Pengujian dan Analisis Skenario 1 ( pengaruh *preprocessing* terhadap proses klasifikasi )

Pengujian ini dilakukan untuk melihat pengaruh dari penggunaan *non-standard word handling* pada *preprocessing* terhadap performansi sistem. Hasil pengujian dievaluasi dengan menggunakan *10 fold cross validation*, kemudian pengukuran akurasi diukur dengan *confusion matrix*. Hasil dari pengujian ini ditunjukkan

pada Gambar 3.2.




**Gambar 2. Pengaruh Penggunaan Non-Standard Word Handling Terhadap Performansi Sistem**

Berdasarkan Gambar 2, hasil uji *preprocessing* yang menggunakan *Non-standard Word Handling* memiliki nilai yang tinggi dibandingkan dengan hasil uji tanpa *Non-standard Word Handling* dengan memiliki rata – rata akurasi sebesar 84,75%, *precision* 53,69%, *recall* 71,37%. Hasil akurasi dengan tidak menggunakan *Non-standard Word Handling* sebesar 84,68%, *precision* 53,55%, *recall* 70,98%. Dari hasil pengujian ini diketahui bahwa pengujian yang menggunakan *Non-Standard Word Handling* mampu menghasilkan klasifikasi yang lebih akurat (*accuracy*) dan memiliki tingkat keberhasilan yang baik dalam menemukan kembali masing – masing kelas pada dokumen (*recall*), namun tingkat ketepatan sistem dalam menentukan kelas pada seluruh dokumen (*precision*) masih kurang baik walaupun menggunakan *Non-Standard Word Handling*.

#### 4.3 Hasil Pengujian dan Analisis Skenario 2 ( pengaruh ekstraksi fitur terhadap proses klasifikasi )

Pengujian ini dilakukan untuk melihat pengaruh dari penggunaan ekstraksi fitur *TF-IDF*, *Lexicon SentiWordnet*, dan peggabungan *TF-IDF* dan *SentiWordnet* terhadap analisis sentimen. Hasil pengujian dievaluasi dengan menggunakan *10 fold cross validation*, kemudian pengukuran akurasi diukur dengan *confusion matrix*. Hasil dari pengujian ini ditunjukkan pada Gambar 3.



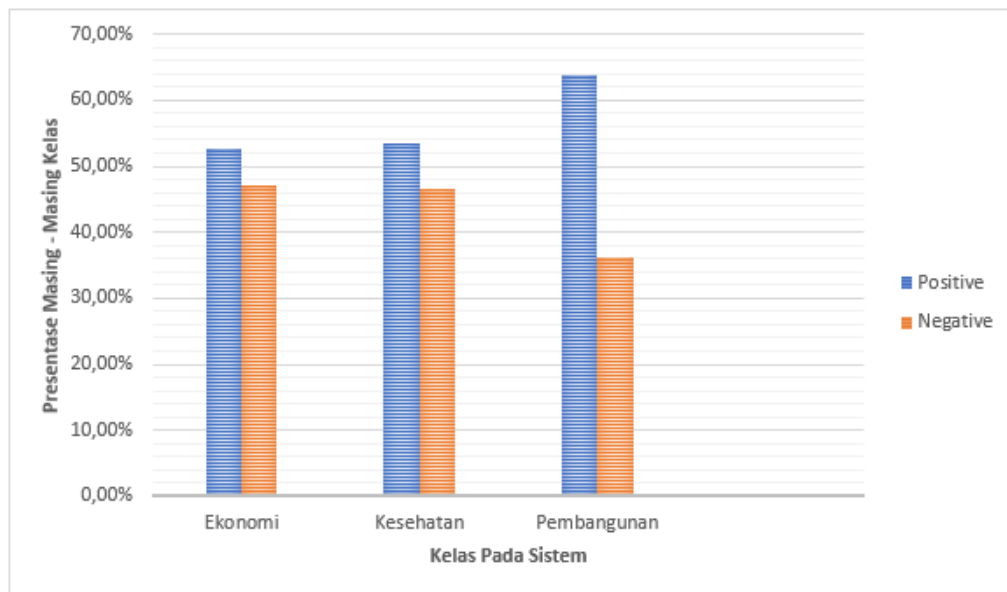
**Gambar 3. Perbandingan Nilai Performansi Berbagai Ekstraksi Fitur**

Berdasarkan Gambar 3, dapat diketahui bahwa akurasi dalam menggunakan ekstraksi fitur *Lexicon SentiWordnet* lebih tinggi dibandingkan dengan akurasi ekstraksi fitur lainnya. Adapun hasil performansi dari *Lexicon SentiWordnet* yaitu 84,75%, akurasi dari *TF-IDF* dan penggabungan *TF-IDF* dan *SentiWordnet* yaitu 84,62%. Dari hasil pengujian ini dapat diketahui bahwa sistem klasifikasi akan lebih baik jika menggunakan

*SentiWordnet* dalam proses ekstraksi fiturnya namun tidak berbeda jauh dengan metode ekstraksi fitur lainnya. Metode ekstraksi fitur ini terbukti dapat meningkatkan akurasi pada pengklasifikasian *Naive Bayes*.

#### 4.4 Hasil Pengujian dan Analisis Skenario 3 ( presentase masing – masing aspek )

Pengujian ini dilakukan untuk mengetahui presentase dari masing – masing aspek yang ada pada dataset berdasarkan dari hasil klasifikasi oleh sistem yang telah dibangun. Hasil dari pengujian ini yaitu berupa nilai presentase tingkat kepuasan masyarakat terhadap kinerja Presiden berdasarkan opini – opini yang telah diambil pada *twitter*. Aspek – aspek tersebut yaitu aspek ekonomi, aspek kesehatan, dan aspek pembangunan. Hasil pengujian ditunjukkan pada Gambar 4.



**Gambar 4. Presentase Nilai Kepuasan Masyarakat**

Berdasarkan gambar 4, dapat dilihat bahwa masing – masing aspek mendapatkan presentase positif yang lebih tinggi dibandingkan dengan presentase kelas negatif. Pada aspek ekonomi, kelas positif mendapatkan nilai yaitu 52,77%, dan kelas negatifnya 47,22%. Pada aspek kesehatan, kelas positif mendapatkan nilai yaitu 53,52% dan kelas negatifnya 46,47%. Pada aspek pembangunan, nilai kelas positifnya yaitu 63,88% dan kelas negatifnya 36,11%. Dapat disimpulkan dari hasil klasifikasi oleh *Naive Bayes* menunjukkan bahwa masyarakat cenderung puas terhadap kinerja Presiden Indonesia dalam aspek ekonomi, aspek kesehatan, dan aspek pembangunan.

#### 5. Kesimpulan

Berdasarkan pengujian dan analisis yang telah dilakukan, berdasarkan dataset *tweet* yang diambil sendiri dengan cara *crawling* dari *twitter* menggunakan *twitterscraper* maka kesimpulan yang dapat diambil adalah tahap *preprocessing* dengan menggunakan *Non-Standard Word Handling* dengan menggunakan *10 fold cross validation* memiliki hasil yang lebih tinggi dengan rata – rata 84,75%. Selisih yang didapat tidak begitu jauh yaitu 0,07%. Pada pengujian ekstraksi fitur, penggunaan *Lexicon SentiWordnet* memiliki akurasi yang lebih tinggi dibandingkan dengan ekstraksi fitur lainnya yaitu 84,75% dengan selisih 0.13 % dengan metode *TF-IDF* dan penggabungan *TF-IDF* dan *Lexicon SentiWordnet*. Dari hasil klasifikasi menggunakan *Naive Bayes* menunjukkan hasil bahwa terdapat 52,77% masyarakat yang memberikan opini positif terkait kinerja Presiden Indonesia pada aspek ekonomi, 53,52% memberikan opini positif pada aspek kesehatan, dan 63,88% memberikan opini positif pada aspek pembangunan.

Terdapat beberapa saran untuk mengembangkan penelitian berikutnya, yaitu dengan menambahkan lebih banyak lagi kata - kata pada kamus untuk *SentiWordnet* yang digunakan untuk pembobotan agar akurasi dapat meningkat. Saran selanjutnya yaitu dengan mencoba mengkombinasikan *TF-IDF* dengan jenis *Lexicon* lainnya.

**Daftar Pustaka**

- [1] K. Lazaridou and R. Krestel, "Identifying Political Bias in News Articles," *Int. Conf. Theory Pract. Digit. Libr.*, vol. 12, 2016.
- [2] Statista, "Number of monthly active Twitter users worldwide from 1st quarter 2010 to 2nd quarter 2018 (in millions)," *The Statics Portal*, 2018.
- [3] G. A. Buntoro, "Analisis Sentimen Calon Gubernur DKI Jakarta 2017 Di Twitter," *Integer J. Maret*, vol. 1, no. 1, pp. 32–41, 2016.
- [4] P. Jea *et al.*, "ANALISIS SENTIMEN TWITTER MENGGUNAKAN METODE LEXICON-BASED DAN SUPPORT VECTOR MACHINE SENTIMENT ANALYSIS TWITTER USING LEXICON-BASED METHOD AND."
- [5] B. Liu, *Synthesis lectures on human language technologies*. Morgan & Claypool Publisher, 2012.
- [6] A. P. Syah, S. Al Faraby, F. Informatika, and U. Telkom, "ANALISIS SENTIMEN PADA DATA ULASAN PRODUK TOKO ONLINE DENGAN METODE MAXIMUM ENTROPY SENTIMENT ANALYSIS ON ONLINE STORE PRODUCT REVIEWS WITH MAXIMUM," vol. 4, no. 3, pp. 4632–4640, 2017.
- [7] N. Saleena, "ScienceDirect An Ensemble Classification System for Twitter Sentiment Analysis An Ensemble Classification System for Twitter Sentiment Analysis," *Procedia Comput. Sci.*, vol. 132, no. Iccids, pp. 937–946, 2018.
- [8] B. Joyce, "Sentiment Analysis of Tweets for the 2016 US Presidential Election," pp. 5–8, 2016.
- [9] G. A. Buntoro and A. E. Purnamasari, "Sentiment Analysis Candidates of Indonesian Presiden 2014 with Five Class Sentiment Analysis Candidates of Indonesian Presiden 2014 with Five Class Attribute," no. May, 2016.
- [10] P. Sharma, "Prediction of Indian Election Using Sentiment Analysis on Hindi Twitter," pp. 1966–1971, 2016.
- [11] D. Wahyudi, T. Susyanto, and D. Nugroho, "Implementasi dan analisis algoritma stemming nazief & adriani dan porter pada dokumen berbahasa indonesia," pp. 49–56, 2013.
- [12] C. D. Manning, P. Raghavan, and H. Schutze, "An Introduction to Information Retrieval," *Online*, no. c, p. 569, 2009.
- [13] F. Fakhruddin, M. S. Mubarak, F. Informatika, and U. Telkom, "Klasifikasi Sentimen Pada Data Ulasan Produk Toko Online Menggunakan Multinomial Naïve Bayes Sentiment Classification on Online Store Product Reviews Using."
- [14] Kohavi and Provost, "Confusion Matrice." [Online]. Available: [http://www2.cs.uregina.ca/~dbd/cs831/notes/confusion\\_matrix.html](http://www2.cs.uregina.ca/~dbd/cs831/notes/confusion_matrix.html).
- [15] I. M. W. Widiara, A. Herdiani, and I. L. Sardi, "Prediksi Hasil Pemilihan Kepala Daerah Melalui Informasi Twitter Menggunakan Naive Bayes Classifier ( Studi Kasus : Pemilihan Gubernur DKI Jakarta 2017 )," 2017.
- [16] R. Kartika, Y. Sibaroni, and Adiwijaya, "Klasifikasi Sentimen Data Ulasan Produk Pakaian Menggunakan Metode Multinomial Naïve Bayes Berbasis Information Gain dan Query Expansion Ranking Program Studi Sarjana Informatika Fakultas Informatika Universitas Telkom Bandung," 2019.
- [17] I. M. W. Widiara, A. Herdiani, and I. L. Sardi, "Prediksi Hasil Pemilihan Kepala Daerah Melalui Informasi Twitter Menggunakan Naive Bayes Classifier ( Studi Kasus : Pemilihan Gubernur DKI Jakarta 2017 )," 2017.