

Pengaruh *Stopword Removal* dan *Stemming* Terhadap Performa Klasifikasi Teks Komentar Kebijakan *New Normal* Menggunakan Algoritma LSTM

Agil Santosa¹, Intan Purnamasari², Rini Mayasari³

^{1,2,3}Teknik Informatika, Universitas Singaperbangsa Karawang, Indonesia

Jl. H.S. Ronggowaluyo Kel. Puseurjaya Kec. Telukjambe Timur Kab. Karawang Prov. Jawa Barat, 0267641177

agil.santosa17039@student.unsika.ac.id¹, intan.purnamasari@staff.unsika.ac.id², rini.mayasari@staff.unsika.ac.id³

Abstract

The development of information technology has made the popularity of social media increase in recent years, one of which is Youtube. Youtube's popularity make this platform a major source of sentiment where almost everyone tends to express their views in the form of comments. These comment not only express people but also have more meaning about their experiences. Comments originating from social media are unstructured so that in sentiment analysis the preprocessing stage is an important task. There are many techniques used in preprocessing including stopwrod and stemming. However, several studies have shown that the use of stopword and stemming gives different result. Therefore, in this paper, the researcher further analyzes the effect of applying stopword and stemming on Youtube video comment regarding the New Normal policy using Long Short Term-Memory. The result obtained we found that the use of stopword and stemming greatly affects the performance of the model, this is because a lot of information is lost after the stopword process and some words change meaning after stemming.

Keywords: Long Short Term-Memory, Youtube, Classification, Stopword, Stemming

Abstrak

Perkembangan teknologi informasi menjadikan popularitas media sosial meningkat beberapa tahun terakhir, salah satunya yaitu Youtube. Kepopuleran Youtube menjadikan platform ini sebagai sumber utama sentimen dimana hampir setiap orang cenderung mengekspresikan pandangannya dalam bentuk komentar. Komentar ini tidak hanya mengekspresikan seseorang tetapi juga memiliki makna lebih tentang pengalaman mereka. Komentar yang berasal dari media sosial bersifat tidak terstruktur, sehingga dalam analisis sentimen tahap preprocessing menjadi salah satu tugas penting. Ada banyak Teknik yang digunakan dalam preprocessing diantaranya stopword dan stemming. Namun beberapa penelitian telah menunjukkan bahwa penggunaan stopword dan stemming memberikan hasil yang berbeda. Oleh karena itu dalam makalah ini peneliti menganalisis lebih lanjut pengaruh penerapan stopword dan stemming pada komentar video Youtube mengenai kebijakan New Normal menggunakan Long Short Term-Memory. Hasil yang didapatkan kami menemukan bahwa penggunaan stopword dan stemming sangat mempengaruhi performa model, hal tersebut dikarenakan banyaknya informasi yang hilang setelah proses stopword dan terdapat beberapa kata yang mengalami pergantian makna setelah dilakukan stemming.

Kata kunci: Long Short Term-Memory, Youtube, Klasifikasi, Stopword, Stemming

1. PENDAHULUAN

Perkembangan teknologi informasi menjadikan popularitas media sosial meningkat beberapa tahun terakhir, salah satunya media sosial Youtube [1]. Menurut Hootsuite pada tahun 2020, pengguna aktif media sosial Youtube di Indonesia mencapai 88% dari jumlah populasi. Media sosial Youtube merupakan salah satu media yang efektif, dimana pengguna dapat memberikan pendapat dan opininya secara langsung melalui sebuah komentar. Beragam komentar dalam video memiliki makna lebih tentang pengalaman pengguna dalam menyampaikan pendapat. Bagian terpenting dalam mengumpulkan informasi adalah dengan memahami apa yang orang lain pikirkan [2]. Hal ini menjadikan Youtube salah satu *resource* atau sumber *feedback* bagi pemerintah, organisasi swasta, dan penyedia layanan lainnya untuk mendapatkan pendapat tentang produk, layanan, atau kebijakan pemerintah [3]. Setiap komentar didalam video Youtube menghasilkan data tidak terstruktur dan terdapat banyak noise [4]. Analisis sentimen merupakan salah satu metode yang digunakan untuk mengekstrasi informasi dari kumpulan data dengan menentukan polaritas dari sebuah teks berdasarkan sentimen yang mencerminkan teks tersebut [5]. Banyak penelitian yang telah mempresentasikan metode klasifikasi dalam analisis sentimen [6], [7].

Dalam klasifikasi sentimen, langkah pertama yang harus dilakukan adalah *preprocessing data*. *Preprocessing data* merupakan proses penghapusan data tidak terstruktur dari data yang diperoleh [8]. Oleh karena itu peran *preprocessing data* sangat penting karena dapat mempengaruhi akurasi dalam melakukan analisis sentimen [9]. Beberapa langkah dalam *preprocessing data* diantaranya *stopword* dan *stemming* [10]. *Stopword* merupakan kata-kata yang umum dalam Bahasa yang tidak memiliki kontribusi secara arti dalam sebuah kalimat [11], sedangkan *stemming* merupakan penghilangan kata imbuhan dalam sebuah kata kedalam bentuk dasar [10].

Beberapa peneliti telah menganalisis dampak dari *preprocessing data*, seperti yang dilakukan oleh Ladani dan Desai (2020) mengidentifikasi pengaruh *stopword* dalam mengklasifikasikan teks bahasa India, mampu meningkatkan nilai akurasi dan juga mengurangi ukuran *corpus*. Penerapan *stemming* juga meningkatkan akurasi dalam mengklasifikasikan teks Bahasa arab [13]. Dalam penelitian Alam dan Yao (2018) menerapkan *stopword* dan *stemming* menggunakan algoritma *machine learning* tidak menunjukkan peningkatan akurasi. Penelitian lainnya melakukan *preprocessing data* menggunakan *stopword* dan *stemming* meningkatkan akurasi analisis sentimen di semua situasi [15]. Namun apakah penggunaan *stopword* dan *stemming* juga dapat meningkatkan nilai akurasi dalam klasifikasi sentimen dari komentar video Youtube, mengingat komentar dari video Youtube tidak terstruktur dan mengandung banyak *noise*.

Berdasarkan penjelasan diatas, penelitian ini ingin memberikan kontribusi di bidang penelitian klasifikasi sentimen untuk mengetahui



pengaruh penerapan *stopword* dan *stemming* dalam mengklasifikasi komentar video Youtube yang menanggapi kebijakan *New Normal* menggunakan *Long Short Term-Memory* (LSTM). Penggunaan algoritma ini dipilih karena menurut Kedia dan Rasu (2020), LSTM menggunakan struktur yang disebut *gate* untuk membantu menyimpan informasi yang diperlukan, sehingga dapat mempertahankan informasi jangka panjang. Dalam penelitian yang dilakukan Fang dkk (2021) menerapkan algoritma *Long Short Term-Memory* untuk memprediksi kerentanan banjir berhasil mendapatkan akurasi 93.75%. penelitian lainnya dilakukan dalam mengklasifikasi *tweets* laporan masalah di Surabaya berhasil mendapatkan akurasi 87% menggunakan algoritma *Long Short Term-Memory* [7].

2. METODOLOGI PENELITIAN

Penelitian ini dilakukan dengan metodologi *Team Data Science* (TDSP). TDSP merupakan metodologi yang dikeluarkan oleh Microsoft yang bertujuan untuk meningkatkan kolaborasi dan *best practice* dalam penelitian *data science* [15]. Terdapat beberapa fase dalam metodologi TDSP diantaranya:

2.1. *Bussiness understanding*

Yaitu fase penentuan tujuan bisnis dan rencana penelitian.

2.2. *Data acquisition and understanding*

Pada fase ini beberapa proses akan dilakukan seperti pengumpulan data dengan memanfaatkan *tools Webdriver selenium* untuk mengambil komentar video Youtube yang berkaitan dengan kebijakan *New Normal*. Kemudian dari data komentar yang didapatkan akan dilakukan *preprocessing data* sehingga mesin dapat dengan mudah menguraikannya dan dapat direpresentasikan oleh algoritma [16]. *Preprocessing data* itu sendiri terbagi menjadi beberapa tahapan diantaranya:

2.3. *Modelling*

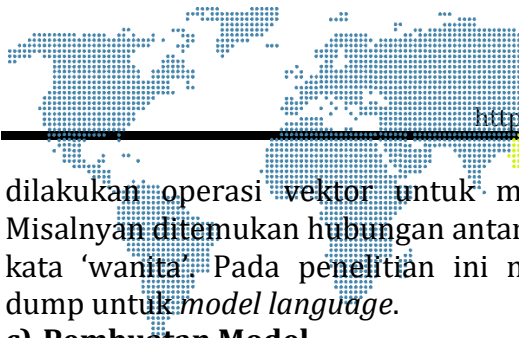
Modelling merupakan fase pembuatan model. Fase ini dibagi menjadi beberapa tahapan, diantaranya:

a) *Splitting data*

Data yang sebelumnya telah melalui proses *tokenizing* selanjutnya akan dilakukan *splitting data*, yaitu membagi dataset menjadi dua, yaitu *training set* dan *test set*. Dimana *training set* akan digunakan untuk proses *training* model, sedangkan *test set* digunakan untuk menguji performa dari model. Berdasarkan penelitian Wildan dkk (2019) menunjukkan bahwa hasil terbaik diperoleh dengan menggunakan perbandingan 80:20, sehingga dalam penelitian ini rasio perbandingan yang akan digunakan yaitu 80:20 untuk *training set* dan *test set* secara berurutan.

b) *Word Embedding*

Pada tahapan ini implementasi *Word embedding* yaitu proses merepresentasikan kata ke dalam sebuah angka tau vektor, sehingga dapat



dilakukan operasi vektor untuk melihat kedekatan dari kata tersebut. Misal nya ditemukan hubungan antara vektor dari kata 'pria' dan vektor dari kata 'wanita'. Pada penelitian ini menggunakan FastText dan Wikipedia dump untuk *model language*.

c) Pembuatan Model

Pada tahap ini dataset akan dilakukan training model *Long Short-Term Memory* menggunakan bahasa pemrograman Python 3 dengan library Keras.

2.4. Deployment

Pada fase ini model yang telah dibuat akan dilakukan test dan evaluasi dari *data test* yang sebelumnya belum pernah di *training*.

3. HASIL DAN PEMBAHASAN

Hasil penelitian ini dilakukan untuk mengetahui pengaruh dari penerapan *stopword removal* dan *stemming* pada tahap *preprocessing* menggunakan algoritma *Long Short Term-Memory*. Analisis menggunakan Google Colab dengan menggunakan bahasa pemrograman python 3 dan 12GB RAM.

3.1. Bussiness understanding

Tujuan dari penelitian ini adalah untuk mengetahui pengaruh dari penerapan *stopword removal* dan *stemming* pada tahap *preprocessing* terhadap performa klasifikasi teks komentar video Youtube mengenai kebijakan *New Normal* menggunakan algoritma *Long Short Term-Memory*.

3.2. Data Acquisition and understanding

Selanjutnya pada tahap ini, beberapa proses akan dilakukan, termasuk tahap pengumpulan dan persiapan data (*preprocessing*) untuk dapat digunakan sebagai *dataset* yang nanti akan diproses menggunakan algoritma. Pengumpulan data dilakukan dengan menggunakan Webdriver Selenium untuk mendapatkan data komentar video yang berkaitan dengan kebijakan *New Normal* di media sosial Youtube. Setelah proses pengumpulan data selesai, dilanjutkan ke proses pemahaman data. Proses pemahaman data dilakukan untuk menentukan data yang dibutuhkan dari data yang telah diperoleh serta pelabelan data yang digunakan sebagai *train dataset*. Kemudian langkah selanjutnya dilakukan beberapa tahap *preprocessing*, salah satunya adalah pembersihan data guna menghilangkan atribut atau kolom yang tidak digunakan dan pembersihan data berupa *emoticon*, simbol-simbol, angka, maupun karakter selain huruf yang tidak memiliki arti. Berikut rincian setiap tahapan.

3.2.1. Pengumpulan Data

Pengumpulan data dilakukan pada tanggal 26 mei 2020 sampai 9 april 2021. Data komentar yang didapatkan sebanyak 53.762 baris dengan atribut *username* dan *comment* yang diambil dari 20 video Youtube yang berkaitan

dengan kebijakan *New Normal*. Berikut merupakan judul video yang digunakan akan ditampilkan pada Tabel 1.

Tabel 1. Judul video Youtube

No	Judul video
1	Terdampak Covid-19, RI Siap Masuki Era New Normal? (CNBN Indonesia)
2	Jelang New Normal, Bandara Soekarno Hatta Perketat Persyaratan Calon Penumpang (KOMPASTV)
3	Sorotan: Indonesia Bersiap Jalani New Normal (KOMPASTV)
4	Sorotan: Indonesia Bersiap Menuju New Normal? (KOMPASTV)
5	[FULL] Jokowi: New Normal, Kita Harus Berkompromi Dengan Covid (KOMPASTV)
6	Skenario New Normal, Masyarakat Harus Berdamai, Mahfud: Virus Corona Seperti Istri (Trimbunnews.com)
7	Implementasi dan Konsekuensi 'New Normal' (CNN Indonesia)
8	'New Normal' dan Implikasinya untuk Indonesia (CNN Indonesia)
9	Selamat Datang "New Normal"! (CNN Indonesia)
10	Akankah New Normal Berpotensi Picu Gelombang Kedua Virus Corona? (KOMPASTV)
11	Hadapi "New Normal" di Tengah Pandemi (CNN Indonesia)
12	Sorotan: Indonesia Bersiap Jalani New Normal (KOMPASTV)
13	Catat! Mulai 1 Juni Kebijakan New Normal, Jurusan Pamungkas Selamatkan Ekonomi? tvOne (tvOneNews)
14	Anies Tarik "Rem Darurat", Jakarta PSBB Total (CNN Indonesia)
15	Ini Usul Ridwan Kamil ke Anies Soal PSBB Penuh di DKI Jakarta (KOMPASTV)
16	Bersiap PSBB Ketat di Jakarta, Asosiasi Mal: Jilid 2 Ini Kami Sudah Babak Belur! (KOMPASTV)
17	Beda Suara antara Anies Baswedan dan Pusat Soal Kebijakan PSBB, Ada Apa? (KOMPASTV)
18	Wali Kota Bogor Bicara Terkait PSBB (CNN Indonesia)
19	INDONESIA TERSERAH' Buntut Plin plan Kebijakan Negara tvOne (tvOneNews)
20	TAJAM! Kritik Keras Rizal Ramli Kepada Presiden Jokowi Dalam Menghadapi Covid-19 ILC tvOne (Indonesia Lawyers Club)

Tabel 2. Contoh hasil pengumpulan data

No	Username	Comment
1	Lisa Asli	ya Tuhan sembuhkanlah Indonesia kami dari wabah virus covid 19 luputkanlah di muka bumi supaya bisa new normal kembali
2	Siti Halimah	Alhamdulillah, smga negri ini semakin membaik... Bangkit indonesia ku
3	Yadi sky	New prank Nih di tunggu. Pada sesi new normal.

Pada Tabel 2 ditunjukkan contoh hasil komentar yang didapatkan dari hasil *scrapping* menggunakan Webdriver selenium.

3.2.2. Preprocessing data

Data komentar yang telah didapatkan kemudian dilakukan preprocessing yang bertujuan untuk membersihkan data atau atribut yang tidak relevan dengan penelitian yang dilakukan. Serta mengkonversi kata sehingga memiliki standar yang sama. Berikut beberapa tahapan preprocessing:

a) Casefolding dan cleansing

Pada tahap ini data komentar akan dilakukan penghapusan kolom atau atribut *Username* dikarenakan tidak relevan dengan penelitian yang akan dilakukan. Selain penghapusan atribut atau kolom yang tidak digunakan, pada tahap ini juga dilakukan pembersihan data berupa emoticon, simbol-simbol, angka, maupun karakter selain huruf yang tidak memiliki arti. Kemudian semua huruf akan dijadikan huruf kecil (*lowercase*). Pada Tabel 3 merupakan contoh proses hasil dari *casefolding* dan *cleansing*.

Tabel 3. Contoh hasil *casefolding* dan *cleansing*

Proses	Comment
Data	Ya Tuhan sembuhkanlah Indonesia kami dari wabah virus Covid 19 luputkanlah di muka bumi supaya bisa New Normal kembali
<i>Casefolding</i>	ya tuhan sembuhkanlah indonesia kami dari wabah virus covid 19 luputkanlah di muka bumi supaya bisa new normal kembali
<i>Cleansing</i>	ya tuhan sembuhkanlah indonesia kami dari wabah virus covid 19 luputkanlah di muka bumi supaya bisa new normal kembali

b) Stopword Removal

Proses ini akan menghapus kata umum yang biasanya muncul dalam jumlah besar dan dianggap tidak memiliki makna. Pada tahap ini menggunakan *library* Sastrawi untuk melakukan *stopword removal*. Perbedaan contoh hasil sebelum dan sesudah dilakukan *stopword removal* dapat dilihat pada Tabel 4.

Tabel 4. Perbedaan contoh hasil sebelum dan sesudah dilakukan *stopword removal*

Proses	Comment
Data	ya tuhan sembuhkanlah indonesia kami dari wabah virus covid 19 luputkanlah di muka bumi supaya bisa new normal Kembali
<i>Stopword removal</i>	tuhan sembuhkanlah indonesia dari wabah virus covid 19 luputkanlah muka bumi bisa new normal

c) Stemming

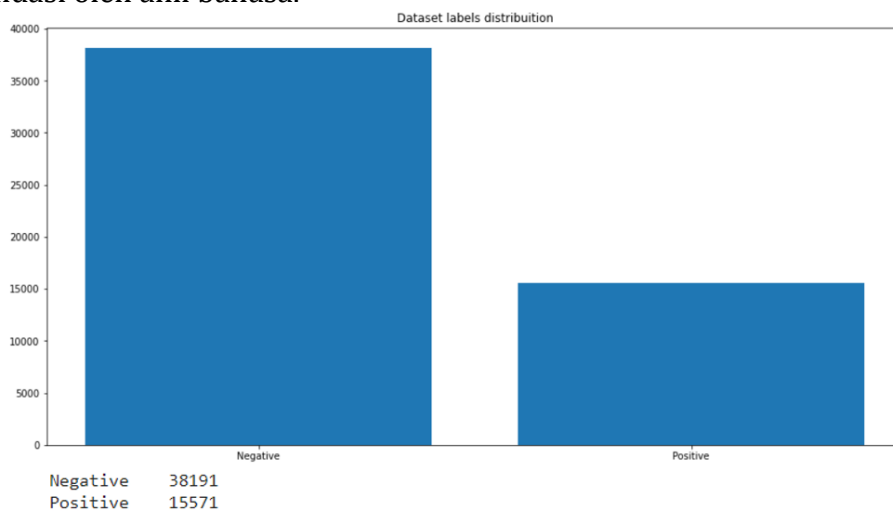
Selanjutnya, proses *stemming* akan memfilter kata yang memiliki imbuhan akan dikembalikan ke dalam bentuk baku. Seperti kata “memukul” akan menjadi “pukul”. Pada Tabel 5 ditunjukkan hasil penerapan *stemming*.

Tabel 5. Hasil penerapan *stemming*

Proses	Comment
Data	tuhan sembahkanlah indonesia dari wabah virus covid 19 luputkanlah muka bumi bisa new normal
Stopword removal	tuhan sembuh indonesia dari wabah yirus covid 19 luput muka bumi bisa new normal

d) Labelling

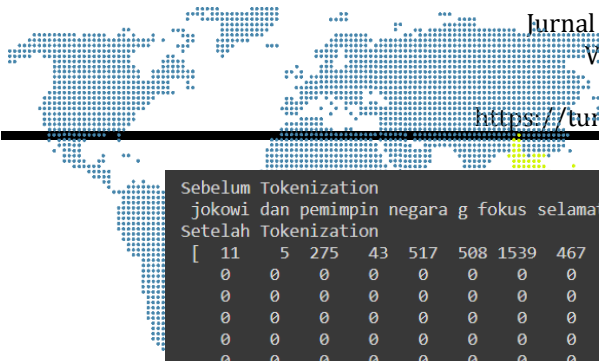
Pemberian label pada komentar dilakukan secara semi-manual dengan menterjemahkan data ke dalam bahasa Inggris sehingga akan ditentukan skor polaritas dan sentimen (positif dan negatif) menggunakan *library TextBlob*, kemudian komentar akan diterjemahkan kembali ke bahasa Indonesia dan dilakukan pengecekan secara manual untuk memastikan pelabelan sudah benar sesuai dengan sentimen yang dicerminkan setiap komentar. Berikut merupakan jumlah persebaran label ditunjukkan pada Gambar 1 yaitu, 38.191 komentar berlabel negatif dan 15.571 komentar berlabel positif. Jumlah persebaran label tersebut sebelumnya telah divalidasi oleh ahli bahasa.



Gambar 1. Hasil persebaran jumlah label setiap kategori

e) Tokenizing

Setelah pelabelan pada data, selanjutnya data dilakukan *tokenizing*, yaitu proses pembagian kata dari kalimat menjadi sebuah token, hal tersebut menjadikan setiap kata memiliki bilangan biner. Berikut pada **Gambar 2** merupakan contoh hasil dari *tokenizing*.

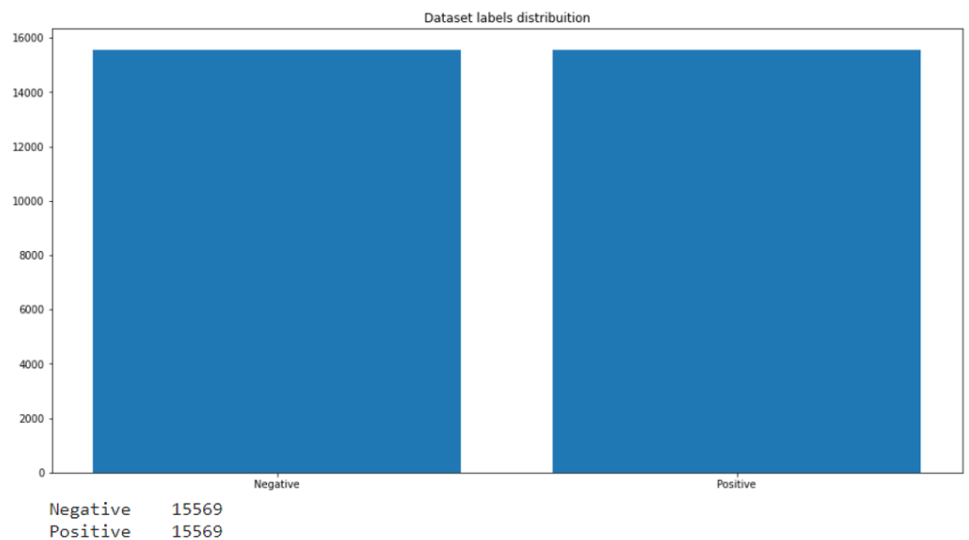


```
Sebelum Tokenization
jokowi dan pemimpin negara g fokus selamatkan nyawa manusia dari corona
Setelah Tokenization
[ 11 5 275 43 517 508 1539 467 429 15 1 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0]
```

Gambar 2. Contoh hasil tokenizing

3.3. Modelling

Sebelum lanjut ke tahap pembuatan model, pada Gambar 1 ditunjukkan hasil jumlah persebaran pada masing-masing kategori, dimana distribusi label memiliki ketimpangan jumlah angka yang sangat besar, dan hal ini dapat mempengaruhi kinerja model saat melatih data tersebut. Untuk itu, *upsampling* dilakukan untuk membuat jumlah masing-masing label menjadi seimbang. Idenya dengan mengambil data mayoritas (*positive*) secara acak agar memiliki jumlah yang sama dengan data minoritas (*negative*). Berikut hasil dari *upsampling* ditunjukkan pada Gambar 3.



Gambar 3. Hasil jumlah persebaran label setelah melalui proses upsampling

3.3.1. Splitting data

Setelah data melalui proses *preprocessing*, selanjutnya yaitu proses *split data* guna membagi data menjadi data *train dataset* dan *test dataset* dengan perbandingan 80:20.

Tabel 6. Hasil *splitting data*

Jumlah data	Training set	Test set
31.138	24.910	6228

Pada table 6 ditunjukkan hasil pembagian sebanyak 24.910 data sebagai *training data set* dan 6228 data sebagai *test dataset*.

3.3.2. Word Embedding

Pada tahap ini, komentar akan diproses sesuai konteks dan akan menghasilkan sebuah vektor. Ada beberapa tahapan sebelum melakukan proses *word embedding*, diantaranya, melakukan pemisahan kalimat menjadi kata (*tokenization*), dan menentukan beberapa parameter yang akan digunakan.

Tabel 7. Parameter *word embedding*

Word embedding	Vector size	Min count	workers	Epoch
Fasttext	300	3	10	1000

Pada Tabel 7 ditunjukkan beberapa parameter yang digunakan, diantaranya *vector_size* merupakan dimensi dari vektor yang akan dihasilkan, *window* merupakan berapa banyak kata disekitarnya yang akan dipertimbangkan untuk dilatih, kemudian *min_count* merupakan berapa minimal kata muncul untuk dijadikan vocab, dan terakhir *workers* merupakan berapa *core* CPU yang akan digunakan untuk melatih model. Setelah konfigurasi model sudah selesai, langkah selanjutnya proses *training* dengan 1000 epoch.

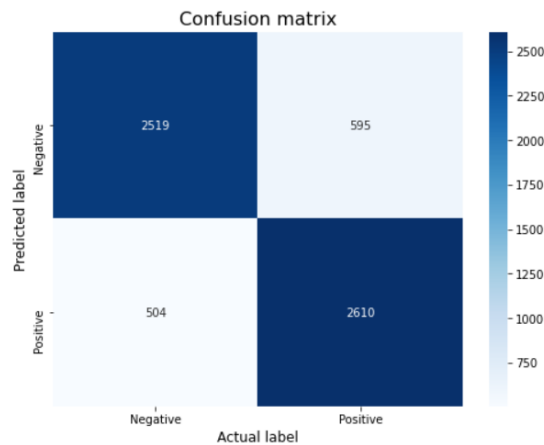
3.3.3. Pembuatan model

Sebelum melakukan *training* pada model LSTM, berikut merupakan *layer* konfigurasi yang dilakukan sebelum proses *training* diantaranya, *embedding layer*, Conv1D, MaxPooling1D, *layer* LSTM dengan 32 neuron, *Dropout* dengan nilai 0.4, dan *Dense* dengan aktivasi sigmoid yang digunakan untuk *fully connected* yang akan memetakan *output* LSTM menjadi *output* 0 dan 1. Dan *optimizer Stochastic Gradient Descent* (SGD) dengan *learning rate* 0.003.

3.4. Deployment

Setelah proses pemodelan selesai, langkah selanjutnya adalah menganalisis dan mengevaluasi dari proses pemodelan yang telah dilakukan. Tujuan dilakukan evaluasi model ini bertujuan untuk mengetahui kinerja dari model itu sendiri apakah model bekerja dengan baik atau sebaliknya. Pada penelitian ini metode yang digunakan untuk mengukur performa model menggunakan *confusion maxtrix* sehingga evaluasi kinerja model menghasilkan akurasi, *recall*, *precision*, *f1-score*. Evaluasi yang akan dilakukan pada penelitian ini terdapat 2 skenario, yaitu menerapkan *stemming* dan *stopword removal* pada tahap *preprocessing* dan tanpa

menerapkan *stemming* dan *stopword removal* pada tahap *preprocessing*. Berikut merupakan hasil kinerja model LSTM dengan 2 skenario.




Gambar 4. Confusion matrix data test tanpa *Stemming* dan *Stop word Removal*

Pada gambar 4 diatas model mampu memprediksi dengan benar komentar negatif sebanyak 2519 dan komentar positif sebanyak 2610. Pada table 8 juga disajikan hasil *precision*, *recall*, dan *recall* dari model tanpa menerapkan *stopword* dan *stemming*.

Tabel 8. Hasil rangkuman model tanpa *Stemming* dan *Stop word Removal*

	Precision	Recall	F1-score	Support
Negatif	0.83	0.81	0.82	3114
Positif	0.81	0.84	0.83	3114
Accuracy			0.82	6228
Macro avg	0.82	0.82	0.82	6228
Weighted avg	0.84	0.83	0.82	6228



Gambar 5. Confusion matrix data test dengan *Stemming* dan *Stop word Removal*

Pada gambar 5 di atas model berhasil memprediksi dengan benar komentar negatif sebanyak 2657 dan 1882 komentar positif. Dibawah ini pada tabel 9 juga disajikan hasil dari *precision*, *recall*, dan *f1-score* model dengan menerapkan *stopword* dan *stemming*.

Tabel 9. Hasil rangkuman model dengan *Stemming* dan *Stop word Removal*

	Precision	Recall	F1-score	Support
Negatif	0.68	0.85	0.76	3114
Positif	0.80	0.60	0.69	3114
Accuracy			0.73	6228
Macro avg	0.74	0.73	0.72	6228
Weighted avg	0.74	0.73	0.82	6228

3.5. Pembahasan

Penelitian ini mengimplementasikan algoritma *Long Short Term-Memory* untuk mengetahui pengaruh penerapan *stopword removal* dan *stemming* pada klasifikasi teks komentar video Youtube mengenai kebijakan *New Normal*. Berikut merupakan pembahasan yang akan dilakukan yaitu hasil evaluasi performa model dan hasil evaluasi klasifikasi tiap label.

a) Hasil Evaluasi Performa Model

Hasil implementasi algoritma *Long Short Term-Memory* dalam mengklasifikasikan sentimen terhadap kebijakan *New Normal* menghasilkan hasil akurasi yang disajikan pada tabel 10.

Tabel 10. Hasil performa model

Skenario	Training accuracy	Training loss	Test accuracy	Test loss
Dengan <i>stopword</i> dan <i>stemming</i>	0.76	0.5	0.73	0.56
Tanpa <i>stopword</i> dan <i>stemming</i>	0.87	0.32	0.82	0.4

Mengacu pada tabel 10 dapat diketahui pengujian terbaik pada model *Long Short Term-Memory* tanpa dilakukan *Stemming* dan *Stop word Removal* pada dataset, menghasilkan akurasi 0.82 dengan *loss* 0.4 berhasil memprediksi 5129 data dengan benar dari total 6228 data. Sedangkan untuk model *Long Short Term-Memory* dengan melakukan *stemming* dan *stopword removal* *test accuracy* hanya mendapatkan 0.73 dengan *loss* 0.56 berhasil memprediksi 4539 data dengan benar dari total 6228 data.

b) Hasil Evaluasi Klasifikasi Tiap Label

Berdasarkan **Gambar 6** dapat ditunjukkan hasil prediksi dari model yang telah dibuat, model berhasil melakukan klasifikasi terhadap data yang

belum memiliki label sentimen. Model mampu menangkap informasi dan mempelajari kalimat dengan baik dengan baik.

```
predict("Alhamdulillah Saya setuju, tapi boong WKWKWW dilihat dari mana ge saya tidak setuju")  
'Negative'  
  
predict("Alhamdulillah Semoga diberi kemudahan dalam menjalankan kebijakan ini")  
'Positive'  
  
predict("Ngomong naon sia lah!!!")  
'Negative'
```

Gambar 6 Hasil evaluasi klasifikasi tiap label

4. SIMPULAN

Berdasarkan eksperimen, pengujian dan analisis yang telah dilakukan dalam mengetahui pengaruh penerapan *stopword removal* dan *stemming* pada tahap *preprocessing* pada algoritma *Long Short Term-Memory*, maka dapat diambil kesimpulan sebagai berikut:

- a) Penggunaan *stopword removal* dan *stemming* sangat mempengaruhi performa model, hal tersebut dikarenakan banyaknya informasi yang hilang setelah proses *stopword removal* dan terdapat beberapa kata yang mengalami pergantian makna setelah dilakukan *stemming*.
- b) Hasil uji model *Long Short Term-Memory* tanpa menggunakan *stopword removal* dan *stemming* mendapatkan skor terbaik dengan akurasi 0.82 dengan *loss* 0.4, *precision* 0.83, *recall* 0.81, dan *f1-score* dengan skor 0.82.

DAFTAR PUSTAKA

- [1] Slamini, Universitas Negeri Jember, Institute of Electrical and Electronics Engineers. Indonesia Section, Institute of Electrical and Electronics Engineers. Indonesia Section. Computer Society Chapter, and Institute of Electrical and Electronics Engineers, *Proceedings, 2019 International Conference on Computer Science, Information Technology, and Electrical Engineering (ICOMITEE 2019) : October 16th-17th 2019, Jember, Indonesia*.
- [2] V. L. Sheela, S. Anita, S. Sarada, and K. Rajmohan, "International Symposium on Induced Mutations in Plants," *In vitro Mutagenesis in Dendrobium CV Sonia*, no. August, p. 118, 2008.
- [3] R. Ahuja, A. Chug, S. Kohli, S. Gupta, and P. Ahuja, "The impact of features extraction on the sentiment analysis," in *Procedia Computer Science*, 2019, vol. 152, pp. 341–348. doi: 10.1016/j.procs.2019.05.008.
- [4] A. Krouska, C. Troussas, and M. Virvou, "The effect of preprocessing techniques on Twitter Sentiment Analysis." [Online]. Available: http://tweenator.com/index.php?page_id=13



- [5] Institute of Electrical and Electronics Engineers, *2018 International Arab Conference on Information Technology (ACIT)*.
- [6] G. K. Pitsilis, H. Ramampiaro, and H. Langseth, "Effective hate-speech detection in Twitter data using recurrent neural networks," *Applied Intelligence*, vol. 48, no. 12, pp. 4730–4742, 2018, doi: 10.1007/s10489-018-1242-y.
- [7] M. Wildan, M. Annur, and B. Kartika, "Klasifikasi Multi-label Pada Laporan Masyarakat Kota Surabaya Melalui Media Sosial Twitter Menggunakan Arsitektur Long Short-Term Memory," 2019.
- [8] J. Mothe *et al.*, *Proceedings of 2019 11th International Conference On Knowledge And Systems Engineering : KSE 2019 : October 24-26, 2019, Da Nang, Vietnam*.
- [9] Surya Engineering College and Institute of Electrical and Electronics Engineers, *Proceedings of the International Conference on Computing Methodologies and Communication : ICCMC 2017 : 18-19, July 2017*.
- [10] Krishna. Bhavsar, Naresh. Kumar, and Pratap. Dangeti, *Natural Language Processing with Python Cookbook*. Packt Publishing, 2017.
- [11] Thomas. Dop, *Hands-On Natural Language Processing with PyTorch 1.x*. Packt Publishing, 2020.
- [12] Sri Eshwar College of Engineering and Institute of Electrical and Electronics Engineers, *2020 6th International Conference on Advanced Computing and Communication Systems (ICACCS)*.
- [13] Y. A. Alhaj, J. Xiang, D. Zhao, M. A. A. Al-Qaness, M. Abd Elaziz, and A. Dahou, "A Study of the Effects of Stemming Strategies on Arabic Document Classification," *IEEE Access*, vol. 7, pp. 32664–32671, 2019, doi: 10.1109/ACCESS.2019.2903331.
- [14] S. Alam and N. Yao, "The impact of preprocessing steps on the accuracy of machine learning algorithms in sentiment analysis," *Computational and Mathematical Organization Theory*, vol. 25, no. 3, pp. 319–335, Sep. 2019, doi: 10.1007/s10588-018-9266-8.
- [15] E. Haddi, X. Liu, and Y. Shi, "The role of text pre-processing in sentiment analysis," in *Procedia Computer Science*, 2013, vol. 17, pp. 26–32. doi: 10.1016/j.procs.2013.05.005.
- [16] A. Kedia and M. Rasu, *Hands-On Python Natural Language Processing: Explore tools and techniques to analyze and process text with a view to building real-world NLP applications*. 2020.
- [17] Z. Fang, Y. Wang, L. Peng, and H. Hong, "Predicting flood susceptibility using LSTM neural networks," *Journal of Hydrology*, p. 125734, 2021, doi: 10.1016/j.jhydrol.2020.125734.
- [18] R. B. Severtson, "What is the Team Data Science Process?," *Journal of Chemical Information and Modeling*, 2017.
- [19] S. Kannan *et al.*, "Preprocessing Techniques for Text Mining," *International Journal of Computer Science & Communication Networks*, vol. 5, no. 1, pp. 7–16, 2015.