



UNIVERSITAS INDONESIA

**Analisis Sentimen dan Pemodelan Topik Pada Jasa Pengiriman
Domestik di Era Covid-19 Berbasis *Time Window Lexicon-TFIDF-
SVM* dan *LDA-Mallet***

TESIS

**YUSAK SUTIKNO
1906322316**

**FAKULTAS TEKNIK
PROGRAM STUDI PASCA SARJANA TEKNIK INDUSTRI
DEPOK
2020**



UNIVERSITAS INDONESIA

**Analisis Sentimen dan Topic Modeling Pada Jasa Pengiriman
Domestik di Era Covid-19 Berbasis *Time Window Lexicon-TFIDF-
SVM* dan *LDA-Mallet***

TESIS

Diajukan sebagai salah satu syarat untuk memperoleh gelar Magister

**YUSAK SUTIKNO
1906322316**

**FAKULTAS TEKNIK
PROGRAM STUDI PASCA SARJANA TEKNIK INDUSTRI
KEKHUSUSAN REKAYASA DATA DAN KUALITAS
DEPOK
April 2020**

HALAMAN PERNYATAAN ORISINALITAS

Tesis ini adalah hasil karya saya sendiri, dan semua sumber baik yang dikutip maupun yang dirujuk telah saya nyatakan dengan benar.

Nama : Yusak Sutikno

NPM : 1906322316

Tanda Tangan :

A handwritten signature in blue ink, appearing to read 'Yusak Sutikno', with a horizontal line extending to the right.

Tanggal : 16 April 2021

HALAMAN PENGESAHAN

Tesis ini diajukan oleh :
Nama : Yusak Sutikno
NPM : 1906322316
Program Studi : Teknik Industri
Judul Tesis : Analisis Sentimen dan Pemodelan Topik Pada Jasa Pengiriman Domestik di Era Covid-19 Berbasis *Time Window Lexicon-TFIDF-SVM* dan *LDA-Mallet*

Telah berhasil dipertahankan di hadapan Dewan Penguji dan diterima sebagai bagian persyaratan yang diperlukan untuk memperoleh gelar Magister Teknik pada Program Studi Teknik Industri, Fakultas Teknik, Universitas Indonesia.

DEWAN PENGUJI

Pembimbing : Dr. Zulkarnain, S.T., M.T.

()

Penguji : Dr. Arian Dhini, S.T., M.T.

()

Penguji : Dr. rer.pol. Romadhani Ardi, S.T., M.T.

()

Ditetapkan di : Depok

Tanggal : 27 April 2021

KATA PENGANTAR

Puji syukur saya panjatkan kepada Tuhan Yang Maha Esa, karena atas berkat dan rahmat-Nya, saya dapat menyelesaikan tesis ini. Penulisan tesis ini dilakukan dalam rangka memenuhi salah satu syarat untuk mencapai gelar Master Teknik Jurusan Teknik Industri pada Fakultas Teknik Universitas Indonesia. Saya menyadari bahwa, tanpa bantuan dan bimbingan dari berbagai pihak, dari masa perkuliahan sampai pada penyusunan tesis ini, sangatlah sulit bagi saya untuk menyelesaikan tesis ini. Oleh karena itu, saya mengucapkan terima kasih kepada:

- 1) Dr. Zulkarnain S.T., M.T., selaku dosen pembimbing yang telah menyediakan waktu, tenaga, dan pikiran untuk mengarahkan saya dalam penyusunan tesis ini;
- 2) manajemen dan dosen-dosen senior Universitas Kristen Krida Wacana (UKRIDA) yang telah memberikan kesempatan dan dukungan material maupun moral;
- 3) istri dan anak saya yang selalu memberikan dukungan dan semangat; dan
- 4) teman-teman yang telah banyak membantu dalam menyelesaikan tesis ini.

Akhir kata, saya berharap Tuhan Yang Maha Esa berkenan membalas segala kebaikan semua pihak yang telah membantu. Semoga tesis ini membawa manfaat bagi pengembangan ilmu.

Depok, 11 April 2021

Penulis

**HALAMAN PERNYATAAN PERSETUJUAN PUBLIKASI
TUGAS AKHIR UNTUK KEPENTINGAN AKADEMIS**

Sebagai sivitas akademik Universitas Indonesia, saya yang bertanda tangan di bawah ini:

Nama : Yusak Sutikno
NPM : 1906322316
Program Studi : Teknik Industri
Jenis Karya : Tesis

demikian pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Indonesia **Hak Bebas Royalti Noneksklusif (*Non-exclusive Royalty-Free Right*)** atas karya ilmiah saya yang berjudul:

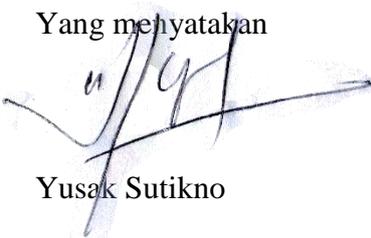
‘Analisis Sentimen dan Pemodelan Topik Pada Jasa Pengiriman Domestik di Era
Covid-19 Berbasis *Time Window Lexicon-TFIDF-SVM* dan *LDA-Mallet*’

Dengan Hak Bebas Royalti Noneksklusif ini Universitas Indonesia berhak menyimpan, mengalihmedia/format-kan, mengelola dalam bentuk pangkalan data (database), merawat, dan memublikasikan tugas akhir saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan sebagai pemilik Hak Cipta.

Demikian pernyataan ini saya buat dengan sebenarnya.

Dibuat di : Depok
Pada tanggal : 16 April 2021

Yang menyatakan


Yusak Sutikno

ABSTRAK

Nama Mahasiswa : Yusak Sutikno
Program Studi : Teknik Industri
Judul : Analisis Sentimen dan Pemodelan Topik Pada Jasa Pengiriman Domestik di Era Covid-19 Berbasis *Time Window Lexicon-TFIDF-SVM* dan *LDA-Mallet*
Pembimbing : Dr. Zulkarnain S.T, M.T.

Pandemi covid-19 dan kebijakan-kebijakan penanggulangannya telah mengubah cara hidup dan kebiasaan banyak orang di seluruh dunia. Terbatasnya pergerakan dan aktivitas masyarakat mendorong mereka untuk mengandalkan sektor pengiriman barang dalam upaya pemenuhan kebutuhan. Hal ini menjadikan sektor usaha pengiriman barang menjadi bagian penting dalam pemenuhan kebutuhan masyarakat di tengah pandemi. Tersedianya akun layanan resmi tiap penyedia barang di media sosial Twitter sebagai wadah pengaduan dan aspirasi pelanggan, memungkinkan untuk dilakukan analisis tren kebutuhan hingga mengukur kepuasan pelanggan terhadap layanan sektor jasa ini sebelum dan selama pandemi.

Penelitian mengenai analisis sentimen pelanggan terhadap suatu produk maupun jasa sudah banyak dilakukan, namun implementasi pendekatan analisis *Time Window Lexicon-TFIDF-SVM* dan pemodelan topik LDA-Mallet terintegrasi belum banyak dilakukan, terutama dalam konteks analisis sentimen pada sektor jasa pengiriman barang. Penelitian ini menggunakan data Twitter yang diperoleh dengan metode *scrapping* dengan rentang waktu Oktober 2019 - September 2020 pada lima penyedia layanan pengiriman barang paling populer di Indonesia.

Pendekatan leksikon dipergunakan dalam pembentukan data latih, dimana dari data latih ini diperoleh model klasifikasi memperoleh tingkat akurasi 89,21% kemudian diinferensikan dengan pendekatan statistik TFIDF-SVM untuk memprediksi polaritas sentimen keseluruhan data. Penelitian ini memberikan hasil bahwa: (1) Pandemi covid-19 melalui parameter kebijakan penanganan pandemi secara signifikan meningkatkan aktivitas penyampaian keluhan/aspirasi dimana hal ini menunjukkan terjadinya peningkatan jumlah layanan yang diberikan; (2) sistem pelayanan pengiriman belum cukup kuat untuk menghadapi fluktuasi permintaan, dimana peningkatan jumlah pelayanan dibarengi juga dengan peningkatan ketidakpuasan yang terindikasi dari meningkatnya polaritas sentimen ‘Negatif’ selama pandemi. Pada periode tiga bulan kedua terlihat bahwa adaptasi dan perbaikan layanan hanya terjadi pada sebagian penyedia layanan saja; dan (3) terdapat beberapa perubahan topik keluhan/aspirasi yang dilihat pada rentang waktu sebelum pandemi, tiga bulan pertama pandemi, dan tiga bulan kedua pandemi.

Kata kunci :

Analisis sentimen, *time window sentiment analysis*, *mallet* pemodelan topik, TF-IDF SVM, jasa pengiriman barang

ABSTRACT

Name : Yusak Sutikno
Study Program : Industrial Engineering
Title : Sentiment Analysis and Topic Modeling in Domestic Delivery Services in the Covid-19 Era Based on the Lexicon-TFIDF-SVM and LDA-Mallet Time Window
Counsellor : Dr. Zulkarnain S.T, M.T.

The Covid-19 pandemic and activity restriction policies in an effort to contain its spread have changed the ways of life and habits of many people around the world. Limited movement and community activities encourage them to rely on the shipping sector to meet their needs. This makes the delivery of goods an important part of meeting people's needs in the midst of a pandemic. The availability of official service accounts of each goods provider on Twitter social media as a forum for complaints and customer aspirations, enabling analysis of service needs trends and measuring customer satisfaction with these service sector services before and during the pandemic.

Research on customer sentiment analysis towards a product or service has been done a lot, but the implementation of the *lexicon-tfidf-svm time window* approach integrating with *LDA-Mallet* topic modeling has not been done much, especially in the context of sentiment analysis in the freight forwarding sector. This research uses Twitter data obtained by the scrapping method from October 2019 - September 2020 on the five most popular delivery service providers in Indonesia.

The lexicon approach is used in the formation of training data, where the classification model of this training data accurate rate of 89.21% is obtained which is then referred to predict the polarity of the overall sentiment of the data by the TFIDF-SVM statistical approach. This study provides the results that: (1) the Covid-19 pandemic through the parameters of the pandemic management policy significantly increased the activity of submitting complaints/aspirations, indicating an increase in the number of requests for services or services provided; (2) the delivery service system is not yet strong enough to deal with fluctuations in increased demand, where an increase in the number of services is accompanied by an increase in dissatisfaction, although it is not significant for all service providers. In the second three-months period, it appears that the process of adaptation and improvement of services only occurred in part of service providers; and (3) there were some changes in the topic of complaints/aspirations that were seen in the timeframe before the pandemic, the first three months of the pandemic, and the second three months of the pandemic.

Keywords :

Sentiment analysis, time window sentiment analysis, mallet topic modeling, TF-IDF SVM, delivery service sentiment analysis.

DAFTAR ISI

| | |
|--|------------|
| HALAMAN JUDUL | i |
| HALAMAN PERNYATAAN ORISINALITAS | iii |
| HALAMAN PENGESAHAN | iv |
| KATA PENGANTAR | v |
| HALAMAN PERNYATAAN PERSETUJUAN PUBLIKASI | vi |
| ABSTRAK | vii |
| DAFTAR ISI | ix |
| DAFTAR GAMBAR | xi |
| DAFTAR TABEL | xii |
| DAFTAR PERSAMAAN | xiv |
| DAFTAR LAMPIRAN | xiv |
| BAB 1 PENDAHULUAN | 1 |
| 1.1 Latar Belakang | 1 |
| 1.2 Perumusan Masalah | 4 |
| 1.3 Tujuan Penelitian | 4 |
| 1.4 Manfaat Penelitian | 4 |
| 1.5 Batasan Penelitian..... | 5 |
| 1.6 Sistematika Penulisan | 5 |
| BAB 2 TINJAUAN PUSTAKA | 7 |
| 2.1 Jasa Pengiriman Barang Domestik di Indonesia..... | 7 |
| 2.2 Kebijakan Terkait Penanganan Pandemi | 9 |
| 2.3 Sosial Media Twitter..... | 10 |
| 2.3.1 Pengguna Twitter di Indonesia | 11 |
| 2.3.2 Twitter Sebagai Pusat Pengaduan dan Layanan Pelanggan..... | 11 |
| 2.4 <i>Text Mining</i> | 12 |
| 2.5 Analisis Teks..... | 12 |
| 2.6 Analisis Sentimen | 13 |
| 2.6.1 Analisis Sentimen Jendela Waktu..... | 14 |
| 2.6.2 Ekstraksi Fitur dalam Sentimen Analisis..... | 14 |
| 2.6.3 <i>Data Preprocessing</i> | 18 |
| 2.6.4 Klasifikasi | 20 |
| 2.6.5 Pengujian dan Validasi | 23 |
| 2.7 Pemodelan Topik | 25 |
| 2.7.1 <i>Latent Dirichlet Allocation</i> | 25 |
| 2.7.2 LDA-Mallet | 26 |
| 2.8 Penelitian Terkait..... | 27 |
| 2.9 Usulan Penelitian | 28 |

| | |
|--|------------|
| BAB 3 METODE PENELITIAN | 32 |
| 3.1 Rancangan penelitian | 32 |
| 3.1.1 Pengumpulan Data | 33 |
| 3.1.2 Data <i>Preprocessing</i> | 34 |
| 3.1.3 Klasifikasi Data Latih | 36 |
| 3.1.4 Klasifikasi Keseluruhan Data | 38 |
| 3.1.5 Analisis Jendela Waktu..... | 40 |
| 3.1.6 Pemodelan Topik | 40 |
| 3.1.7 Hasil dan Kesimpulan | 41 |
| BAB 4 HASIL DAN PEMBAHASAN | 42 |
| 4.1 Pengumpulan Data | 42 |
| 4.2 Data <i>Preprocessing</i> | 47 |
| 4.3 Klasifikasi Data Latih | 51 |
| 4.4 Klasifikasi Keseluruhan Data | 54 |
| 4.5 Analisis Sentimen Jendela Waktu..... | 61 |
| 4.5.1 Jumlah <i>Tweet</i> Sebelum dan Selama Pandemi | 61 |
| 4.5.2 Polaritas Sentimen Sebelum dan Selama Pandemi | 64 |
| 4.6 Pemodelan Topik | 74 |
| 4.6.1 Topik <i>tweet</i> ‘Negatif’ sebelum pandemi | 74 |
| 4.6.2 Topik <i>tweet</i> ‘Negatif’ periode pertama pandemi | 77 |
| 4.6.3 Topik <i>tweet</i> ‘Negatif’ periode kedua pandemi..... | 81 |
| BAB 5 PENUTUP | 85 |
| 5.1 Kesimpulan | 85 |
| 5.1.1 Analisis Sentimen | 85 |
| 5.1.2 Pemodelan Topik | 86 |
| 5.2 Implikasi Penelitian | 87 |
| 5.2.1 Implikasi Teoritis | 88 |
| 5.2.2 Implikasi Praktis | 88 |
| 5.3 Saran | 88 |
| DAFTAR PUSTAKA | 90 |
| LAMPIRAN-LAMPIRAN..... | L-1 |

DAFTAR GAMBAR

| | |
|--|----|
| Gambar 1.1 Contoh opini terkait pandemi pada jasa pengiriman | 2 |
| Gambar 2.1. Ilustrasi cara kerja SVM | 22 |
| Gambar 2.2. Representasi model LDA..... | 26 |
| Gambar 3.1 Diagram alir tahapan penelitian..... | 32 |
| Gambar 3.2. Kode Python <i>tweet scraping</i> menggunakan pustaka Twint..... | 33 |
| Gambar 3.3. Kode program Python untuk penggabungan seluruh data | 33 |
| Gambar 3.4. Proses <i>normalize case</i> , data <i>cleansing</i> dan <i>tokenization</i> | 34 |
| Gambar 3.5. Proses <i>normalize spelling</i> | 35 |
| Gambar 3.6. Kode proses <i>stopword removal</i> | 36 |
| Gambar 3.7. Kode aturan klasifikasi data latih. | 37 |
| Gambar 3.8. Ilustrasi <i>direct upsampling</i> vs. <i>synthesis upsampling</i> | 38 |
| Gambar 4.1. Data sebaran lokasi pesan | 44 |
| Gambar 4.2. Aktivitas <i>tweet</i> akun resmi penyedia layanan..... | 45 |
| Gambar 4.3. Pengaturan bahasa yang digunakan pengguna | 45 |
| Gambar 4.4. Komposisi <i>tweet preprocessing</i> | 50 |
| Gambar 4.5. Batasan pengambilan sampel data latih (<i>boxplot</i> distribusi data)..... | 52 |
| Gambar 4.6. Polaritas sentimen data latih | 54 |
| Gambar 4.7. Komposisi data <i>training</i> sebelum proses <i>balancing</i> | 55 |
| Gambar 4.8. Komposisi data <i>training</i> sesudah proses <i>balancing</i> | 55 |
| Gambar 4.9. Hasil uji model dengan <i>10-fold cross validation</i> | 58 |
| Gambar 4.10. Polaritas sentimen keseluruhan data..... | 59 |
| Gambar 4.11. Total Jumlah <i>tweet</i> masing-masing penyedia layanan | 61 |
| Gambar 4.12. Tren jumlah <i>tweet</i> sebelum dan selama pandemi | 62 |
| Gambar 4.13. <i>Tweet</i> 'Negatif' sebelum dan selama pandemi | 64 |
| Gambar 4.14. <i>Tweet</i> 'Netral' sebelum dan selama pandemi | 67 |
| Gambar 4.15. <i>Tweet</i> 'Positif' sebelum dan selama pandemi..... | 71 |
| Gambar 4.16. <i>Coherence score</i> n-topik sentimen 'Negatif' sebelum pandemi..... | 75 |
| Gambar 4.17. <i>Coherence score</i> n-topik sentimen 'Negatif' periode pertama pandemi .. | 78 |
| Gambar 4.18. <i>Coherence score</i> n-topik sentimen 'Negatif' periode kedua pandemi..... | 81 |

DAFTAR TABEL

| | |
|---|----|
| Tabel 2.1. <i>Confussion matrix</i> | 23 |
| Tabel 2.2. Ilustrasi pembagian <i>sub-set</i> data pada <i>10-fold cross validation</i> | 24 |
| Tabel 2.3 Ringkasan penelitian terkait | 30 |
| Tabel 2.4 Ringkasan penelitian terkait (lanjutan)..... | 31 |
| Tabel 3.1. Contoh daftar kata tidak baku..... | 35 |
| Tabel 3.2. Contoh kata <i>stopword</i> | 36 |
| Tabel 3.3. <i>Confussion matrix</i> tiga elemen | 39 |
| Tabel 4.1. Contoh akun dummy dalam data..... | 46 |
| Tabel 4.2. Contoh data hasil proses data <i>cleansing</i> dan tokenisasi | 48 |
| Tabel 4.3. Contoh data hasil proses normalisasi | 49 |
| Tabel 4.4. Contoh data hasil proses <i>stopword removal</i> | 49 |
| Tabel 4.5. Contoh data hasil proses <i>stemming</i> | 50 |
| Tabel 4.6. Format data sebelum dan sesudah <i>preprocessing</i> | 50 |
| Tabel 4.7. Contoh kata sentimen dalam sumber leksikon | 51 |
| Tabel 4.8. Contoh ekstraksi fitur dan perhitungan skor sentimen | 53 |
| Tabel 4.9. Contoh hasil klasifikasi data latih dengan pendekatan <i>rule based</i> | 53 |
| Tabel 4.10. <i>Confussion matrix</i> hasil pelatihan model klasifikasi | 56 |
| Tabel 4.11. Hasil perhitungan presisi, <i>recall</i> , dan <i>f1-score</i> kelas sentimen | 57 |
| Tabel 4.12. Contoh data terklasifikasi 'Negatif' | 60 |
| Tabel 4.13. Contoh data terklasifikasi 'Netral' | 60 |
| Tabel 4.14. Contoh data terklasifikasi 'Positif' | 60 |
| Tabel 4.15. <i>Tweet</i> sebelum dan selama pandemi berdasarkan penyedia layanan | 62 |
| Tabel 4.16. Uji korelasi tren jumlah <i>tweet</i> vs pandemi (cov/psbb)..... | 63 |
| Tabel 4.17. Uji signifikansi korelasi tren jumlah <i>tweet</i> vs pandemi..... | 63 |
| Tabel 4.18. <i>Tweet</i> 'Negatif' sebelum dan selama pandemi | 64 |
| Tabel 4.19. Uji korelasi <i>tweet</i> 'Negatif' vs periode pertama pandemi | 65 |
| Tabel 4.20. Uji signifikansi korelasi <i>tweet</i> 'Negatif' vs periode pertama pandemi..... | 65 |
| Tabel 4.21. Uji korelasi <i>tweet</i> 'Negatif' vs periode kedua pandemi..... | 66 |
| Tabel 4.22. Uji signifikansi korelasi <i>tweet</i> 'Negatif' vs periode kedua pandemi..... | 66 |
| Tabel 4.23. <i>Tweet</i> 'Netral' sebelum dan selama pandemi | 67 |
| Tabel 4.24. Uji korelasi <i>tweet</i> 'Netral' vs periode pertama pandemi | 68 |

| | |
|--|----|
| Tabel 4.25. Uji signifikansi korelasi <i>tweet</i> 'Netral' vs periode pertama pandemi..... | 68 |
| Tabel 4.26. Uji korelasi <i>tweet</i> 'Netral' vs periode kedua pandemi..... | 69 |
| Tabel 4.27. Uji signifikansi korelasi <i>tweet</i> 'Netral' vs periode kedua pandemi..... | 69 |
| Tabel 4.28. Konten <i>tweet</i> 'Netral' bulan Agustus - September 2020..... | 69 |
| Tabel 4.29. <i>Tweet</i> 'Positif' sebelum dan selama pandemi..... | 70 |
| Tabel 4.30. Uji korelasi <i>tweet</i> 'Positif' vs periode pertama pandemi..... | 71 |
| Tabel 4.31. Uji signifikansi korelasi <i>tweet</i> 'Positif' vs periode pertama pandemi..... | 72 |
| Tabel 4.32. Uji korelasi <i>tweet</i> 'Positif' vs periode kedua pandemi..... | 72 |
| Tabel 4.33. Uji signifikansi korelasi <i>tweet</i> 'Positif' vs periode kedua pandemi..... | 72 |
| Tabel 4.34. Konten <i>tweet</i> 'Positif' bulan Agustus - September 2020..... | 73 |
| Tabel 4.35. Topik <i>tweet</i> 'Negatif' sebelum pandemi..... | 75 |
| Tabel 4.36. Topik <i>tweet</i> 'Negatif' periode pertama pandemi..... | 78 |
| Tabel 4.37. Topik <i>tweet</i> 'Negatif' periode kedua pandemi..... | 82 |
| Tabel 5.1. Rangkuman tren topik sebelum dan selama pandemi..... | 87 |

DAFTAR PERSAMAAN

| | |
|--|----|
| Persamaan 2.1. Perhitungan nilai TF-IDF | 18 |
| Persamaan 2.2. Perhitungan nilai akurasi berdasarkan <i>confussion matrix</i> | 23 |
| Persamaan 2.3. Contoh perhitungan nilai presisi kelas ‘Positif’ | 24 |
| Persamaan 2.4. Contoh perhitungan nilai <i>recall</i> kelas ‘Positif’ | 24 |
| Persamaan 2.5. Perhitungan nilai <i>f1-score</i> | 24 |
| Persamaan 3.1. Perhitungan nilai skor sentimen | 37 |
| Persamaan 3.2. Perhitungan nilai akurasi berdasarkan <i>confussion matrix</i> tiga elemen . | 39 |
| Persamaan 3.3. Perhitungan nilai presisi kelas ‘Positif’ tiga elemen | 39 |
| Persamaan 3.4. Perhitungan nilai presisi kelas ‘Netral’ tiga elemen..... | 39 |
| Persamaan 3.5. Perhitungan nilai presisi kelas ‘Negatif’ tiga elemen..... | 39 |
| Persamaan 3.6. Perhitungan nilai <i>recall</i> kelas ‘Positif’ tiga elemen tiga elemen..... | 39 |
| Persamaan 3.7. Perhitungan nilai <i>recall</i> kelas ‘Netral’ tiga elemen tiga elemen | 40 |
| Persamaan 3.8. Perhitungan nilai <i>recall</i> kelas ‘Negatif’ tiga elemen tiga elemen | 40 |

DAFTAR LAMPIRAN

| | |
|---|-----|
| Lampiran 1. Kode program proses stemming dengan pustaka Sastrawi..... | L-1 |
| Lampiran 2. Kode program ekstraksi fitur dengan pendekatan leksikal | L-2 |

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Sejak merebaknya penyakit yang disebabkan oleh virus korona pada akhir tahun 2019 di Tiongkok hingga ditetapkan sebagai pandemi Covid-19 oleh organisasi kesehatan dunia WHO, hingga 15 Maret 2021 tercatat lebih dari 121 juta orang di seluruh dunia telah terjangkit dimana 2,7 juta diantaranya meninggal dunia (Worldometers, 2021). Virus ini begitu cepat menular dan menjangkiti manusia karena dapat menyebar lewat percikan pernafasan dan sentuhan terhadap benda-benda yang telah terkontaminasi. Belum ada metode pengobatan yang benar-benar ampuh hingga saat ini meskipun berbagai penelitian dan pengembangan obat-obatan terus dilakukan, penanggulangan pandemi yang dapat dilakukan adalah mengurangi dan mencegah penyebarannya.

Berbagai upaya untuk mencegah penyebaran virus ini terus dilakukan termasuk pembatasan pergerakan dan interaksi antar manusia, karantina terhadap penderita, penundaan dan pembatalan acara yang melibatkan banyak orang, penutupan berbagai fasilitas, baik fasilitas umum maupun tempat usaha, hingga diberlakukannya kebijakan-kebijakan pembatasan yang dikeluarkan oleh otoritas setempat. Di Indonesia, kebijakan terkait penanganan pandemi Covid-19 tertuang pada Peraturan Pemerintah Nomor 21 Tahun 2020, yang mengatur pembatasan sosial berskala besar dan Keputusan Presiden Nomor 11 Tahun 2020, yang menyatakan pandemi covid-19 sebagai bencana nasional yang secara resmi berlaku sejak ditandatangani oleh Presiden Republik Indonesia, Joko Widodo, pada tanggal 31 Maret 2021.

Dengan diberlakukannya peraturan-peraturan tersebut, secara langsung maupun tidak langsung membuat aktivitas masyarakat menjadi terbatas. Sehingga untuk memenuhi berbagai macam kebutuhannya sebagian masyarakat tidak lagi keluar rumah untuk mencari/membeli barang sendiri tetapi beralih pada jasa pengiriman barang. Perubahan ini sesuai dengan data yang menyebutkan adanya tren kenaikan jumlah penggunaan jasa logistik dan pengiriman barang selama pandemi (Huda & Hidayat, 2020). Hal ini menjadikan sektor usaha logistik maupun pengiriman barang menjadi bagian penting dalam pemenuhan kebutuhan masyarakat selama pandemi.

Akan tetapi, meskipun pemerintah telah memasukkan sektor jasa logistik dan pengiriman barang dalam sektor bisnis yang dapat beroperasi secara normal, berdasarkan beberapa percakapan di media sosial Twitter menyebutkan bahwa pandemi dan kebijakan-kebijakan yang ditetapkan dalam penanganannya berpengaruh terhadap kelancaran arus distribusi barang yang menyebabkan banyaknya keluhan-keluhan terkait jasa pengiriman barang seperti yang ditunjukkan pada komentar-komentar negatif di Twitter pada Gambar 1.1. Meningkatnya keluhan terkait suatu produk/layanan menunjukkan telah terjadi penurunan terhadap kepuasan pelanggan akan produk/layanan yang bersangkutan.



Gambar 1.1 Contoh opini terkait pandemi pada jasa pengiriman

Untuk itu perlu dilakukan analisis lebih mendalam apakah pandemi dan kebijakan-kebijakan terkait penanganan pandemi tersebut secara signifikan berkorelasi dengan tingkat kepuasan pelanggan terhadap layanan jasa pengiriman barang ini.

Salah satu metode untuk mengetahui tingkat kepuasan pelanggan terhadap suatu layanan adalah dengan metode analisis sentimen. Analisis sentimen merupakan bidang ilmu yang mempelajari opini, penilaian, persetujuan, sikap, hingga emosi seseorang akan suatu objek/topik permasalahan (Liu, 2015). Objek/topik permasalahan tersebut dapat berupa kepuasan terhadap kualitas suatu produk maupun layanan, penerimaan akan suatu kebijakan, pendapat mengenai isu-isu yang bersifat spesifik, dan lain-lain. Dalam konteks pada layanan jasa, sentimen positif dapat diartikan bahwa seseorang memiliki pandangan bahwa suatu layanan telah memenuhi harapan dari orang yang bersangkutan, atau sebaliknya sentimen negatif dapat diartikan bahwa seseorang memiliki pandangan bahwa layanan tidak memenuhi harapan.

Analisis sentimen sebagai salah satu cabang dari analisis teks mampu menginterpretasikan komentar-komentar dari media sosial hingga diperoleh informasi berharga yang menggambarkan polaritasnya terhadap suatu topik/objek bahasan. Mengetahui tendensi polaritas saja tidak banyak berarti tanpa mengetahui topik esensial yang terkandung di dalamnya. Oleh sebab itu, integrasi peringkasan teks dalam analisis sentimen menjadi penting yaitu untuk mengetahui topik-topik penting dari sentimen yang ada. Integrasi peringkasan teks dalam analisis sentimen memungkinkan untuk dilakukan mengingat kedua analisis teks ini memiliki tahapan-tahapan dan metode yang mirip bahkan dapat mempergunakan algoritma yang sama.

Perkembangan teknologi informasi yang sangat pesat saat ini, membuat semua informasi sangat cepat menyebar dalam masyarakat dan mampu menjangkau banyak orang. Data menyebutkan bahwa 202,6 juta atau 73,7% penduduk Indonesia adalah pengguna internet, dan 170,0 juta atau 61,8% adalah pengguna aktif media sosial. Di dalam platform media sosial, setiap orang dapat berinteraksi, beropini dan membagikan pengalamannya dalam menggunakan akan suatu produk ataupun jasa baik itu positif maupun negatif dalam media sosial ini. Besarnya pengguna media sosial ini dapat menjadi sumber *insight* data yang potensial baik untuk kepentingan penelitian maupun pengembangan bisnis.

Twitter sebagai salah satu media sosial terbesar di dunia memberi keuntungan tersendiri baik bagi penyedia suatu layanan maupun pengguna. Penyedia layanan tidak perlu menyiapkan platform layanan pelanggan secara mandiri yang tentu saja membutuhkan biaya yang tidak sedikit. Sedangkan bagi pengguna, adanya layanan pelanggan tersebut

memudahkan dalam memberikan masukan, pendapat, hingga komplain terkait layanan yang diterimanya.

Seperti telah diuraikan di atas, maka penelitian ini bertujuan untuk mengetahui apakah pandemi memiliki korelasi terhadap tren sentimen pada layanan jasa pengiriman barang di Indonesia dengan memanfaatkan media sosial Twitter sebagai sumber data. Penelitian ini juga memberikan peringkasan teks berupa topik-topik yang diekstraksi dari perbincangan hingga keluhan-keluhan untuk dapat dijadikan bahan evaluasi, perbaikan, maupun optimalisasi terkait layanan jasa pengiriman barang tersebut.

1.2 Perumusan Masalah

Adapun berdasarkan latar belakang yang sudah dijabarkan di atas adalah:

- 1) Bagaimanakah sentimen pengguna pada jasa layanan pengiriman barang domestik dan korelasinya terhadap pandemi covid-19 yang diukur menggunakan pendekatan jendela waktu sebelum dan selama pandemi?
- 2) Topik-topik esensial apa saja dari sentimen yang ada terkait layanan jasa pengiriman barang domestik tersebut dan apakah terdapat perbedaan tren topik sebelum dan selama pandemi berlangsung?

1.3 Tujuan Penelitian

Berdasarkan perumusan masalah, penelitian ini bertujuan untuk:

- 1) Untuk mengetahui sentimen pengguna pada jasa layanan pengiriman barang domestik dan korelasinya terhadap pandemi covid-19 yang diukur menggunakan pendekatan jendela waktu sebelum dan selama pandemi.
- 2) Mengetahui topik-topik esensial dari sentimen yang ada terkait layanan jasa pengiriman barang domestik dan mengetahui tren topik sebelum dan selama pandemi yang dapat dipergunakan sebagai bahan evaluasi, perbaikan, dan optimalisasi layanan yang bersangkutan.

1.4 Manfaat Penelitian

Penelitian ini setidaknya memiliki dua manfaat utama yaitu manfaat teoritis dan manfaat praktis. Manfaat teoritis dari penelitian ini adalah menambah kekayaan pustaka tentang implementasi analisis sentimen dan pemodelan topik dengan sumber data teks tak terstruktur. Manfaat praktis dari penelitian ini adalah untuk mengetahui apakah pandemi Covid-19 memiliki korelasi terhadap tren sentimen pada layanan jasa pengiriman barang

domestik di Indonesia, serta menyajikan *topic modeling* berupa topik-topik yang diekstraksi dari percakapan/*tweet* pelanggan untuk dapat dijadikan bahan evaluasi, perbaikan, maupun optimalisasi terkait layanan jasa pengiriman barang.

1.5 Batasan Penelitian

Untuk menghindari meluasnya masalah dalam proses penelitian, maka penulis perlu melakukan pembatasan terhadap masalah penelitian ini. Adapun pembatasan masalah tersebut adalah sebagai berikut:

- 1) Pengambilan data dilakukan pada sosial media Twitter pada masing-masing akun resmi penyedia layanan pengiriman barang domestik dengan metode *scraping* dengan rentang waktu *posting* sebelum pandemi yaitu awal Oktober 2019 sebagai sampel data awal dan data pada saat pandemi (hingga September 2020) sebagai data pembanding. Lima penyedia layanan terpopuler dan terbesar akan dipergunakan sebagai objek penelitian yang mewakili penyedia layanan pengiriman barang di Indonesia.
- 2) Pembobotan sentimen data latih akan mengadopsi kamus sentimen (*InSet Lexicon*) untuk meningkatkan konsistensi dan mengurangi subyektif peneliti maupun kemungkinan sentimen terbalik (Poria, Gelbukh, & Thelwall, 2017).

1.6 Sistematika Penulisan

Secara garis besar penelitian ini akan ditulis dalam beberapa bagian/bab, yaitu:

BAB 1 PENDAHULUAN

Bab ini berisi uraian singkat mengenai latar belakang mengapa analisis sentimen dan pemodelan topik pada pelayanan jasa pengiriman barang ini perlu dilakukan, perumusan masalah yang akan dijawab, pembatasan masalah terhadap lingkup penelitian agar penelitian terfokus pada masalah yang dihadapi dan tujuan penelitian, dan manfaat yang dapat diperoleh melalui penelitian ini.

BAB 2 REVIEW LITERATUR

Bab ini berisi tentang tinjauan pustaka yang menjadi pedoman awal bagi peneliti dalam pengerjaan penelitian ini, mulai dari pembahasan dan pemilihan lingkup penelitian yang sesuai, hingga penggunaan metode-metode penelitian yang telah dikerjakan oleh peneliti lain sebelumnya yang menunjang tercapainya tujuan penelitian.

BAB 3 METODE PENELITIAN

Bab ini berisi tentang uraian tahapan bagaimana penelitian dilakukan. Mulai dari tahap pengumpulan data, *preprocessing*, tahap klasifikasi model, tahap klasifikasi keseluruhan data, tahap peringkasan teks melalui pemodelan topik, analisis hasil, dan kesimpulan penelitian yang didapatkan dari penelitian ini.

BAB 4 HASIL PENELITIAN DAN PEMBAHASAN TEMUAN

Bab ini berisi tentang uraian tahapan, metode dan proses pengolahan data sehingga data yang telah terkumpul mempunyai arti dan memberikan jawaban atas masalah penelitian yang tengah dikaji sesuai dengan metode penelitian yang telah dijabarkan pada bab sebelumnya.

BAB 5 PENUTUP

Bab ini berisi tentang kesimpulan dari hasil penelitian yang didapatkan yaitu temuan-temuan pokok yang menjawab permasalahan penelitian dan saran-saran yang diusulkan peneliti dari hasil penelitian yang telah dilakukan.

BAB 2 TINJAUAN PUSTAKA

2.1 Jasa Pengiriman Barang Domestik di Indonesia

Jasa pengiriman barang di Indonesia terus berkembang seiring semakin berkembangnya bisnis *e-commerce* seiring semakin mudahnya masyarakat mendapatkan akses internet dan meningkatnya jumlah pengguna yang melakukan transaksi belanja secara *on-line*. Peningkatan jumlah dan terjadinya lonjakan permintaan pengiriman barang membutuhkan berbagai inovasi, pengembangan teknologi seperti otomatisasi, bahkan pemain-pemain baru dikarenakan jumlah penyedia jasa pengiriman barang saat ini belum seimbang dengan pertumbuhan pangsa pasar *e-commerce* (Tempo, 2020).

Dalam hal inovasi dan pengembangan teknologi, para penyedia jasa pengiriman barang pada umumnya telah mengadopsi sistem pengirimannya dengan memanfaatkan otomatisasi dengan robot-robot penyortir, digitalisasi proses seperti penggunaan sistem *scan* dan *barcode*. Bahkan pelacakan pengiriman saat ini dapat dilakukan secara *real time* karena beberapa penyedia jasa tersebut telah menyediakan sistem informasi terpadu yang dapat diakses melalui telepon pintar, seperti JNE dengan 'My JNE', J&T Express dengan 'J&T Express Indonesia for Android', atau Pos Indonesia dengan 'QPOSin AJA'.

Cukup banyak penyedia jasa layanan pengiriman barang yang beroperasi di Indonesia saat ini, namun dalam penelitian ini mempergunakan lima penyedia jasa pengiriman barang paling populer sebagai objek analisis berdasarkan data pencarian Google Trends, yaitu:

1. JNE Express

JNE Express merupakan perusahaan penyedia layanan pengiriman barang dengan nama lengkap PT. Tiki Jalur Nugraha Ekakurir. JNE Express didirikan pada tahun 1990 dan melayani berbagai jenis pengiriman barang, dari paket kecil dan dokumen sampai dengan penanganan transportasi, logistik, dan distribusi. Hingga saat ini layanan JNE Express telah mencapai lebih dari 6,000 lokasi dimana lebih dari 150 lokasi telah terhubung secara *on-line* dengan memperkerjakan lebih dari 40,000 orang secara keseluruhan (JNE Express, 2021).

2. J&T Express

J&T Express merupakan perusahaan penyedia layanan pengiriman barang yang tergolong baru di Indonesia yang berada di bawah naungan perusahaan PT. Global Jet Express. Sejak didirikan pada tahun 2015, J&T Express telah memiliki setidaknya 100 pusat penyortiran barang dan lebih 4,000 lokasi yang mampu melayani pengiriman ke seluruh daerah di Indonesia serta memperkerjakan lebih dari 30,000 orang. Pada tahun 2019, J&T Express mampu melakukan pengembangan operasional hingga ke empat negara tetangga yaitu Filipina, Singapura, Thailand, dan Kamboja (J&T Express, 2021).

3. TIKI

TIKI merupakan perusahaan penyedia layanan pengiriman barang dengan nama resmi PT. Citra Van Titipan Kilat. TIKI telah beroperasi sejak 1970 dan saat ini telah memiliki jaringan di 65 kota besar dengan lebih dari 500 kantor perwakilan, memiliki lebih dari 3,700 gerai dan memperkerjakan lebih dari 6,000 orang di seluruh Indonesia (TIKI, 2020).

4. Pos Indonesia

Pos Indonesia merupakan badan usaha milik negara yang dari awal beroperasi hanya menyediakan layanan pengiriman dokumen dan surat-menyurat. Menurunnya permintaan pengantaran dokumen dan surat karena tergerus digitalisasi dan pertumbuhan transaksi *e-commerce* yang semakin meningkat, mendorong Pos Indonesia untuk mengubah bisnisnya dari penyedia jasa yang hanya mengantarkan dokumen dan surat, menjadi pengantar barang dan paket juga yang dimulai pada tahun 2016 (Tempo, 2020). Sejarah keberadaan Pos Indonesia cukup panjang, bahkan Pos Indonesia sudah ada jauh sebelum Indonesia merdeka yaitu didirikan pada tahun 1746 oleh Gubernur Jenderal G.W Baron van Imhoff. Pos Indonesia memiliki infrastruktur jaringan yang sangat lengkap dengan lebih 24,000 titik layanan, menjangkau hampir 100% kabupaten/kota dan kecamatan di seluruh Indonesia (Pos Indonesia, 2021).

5. SiCepat

SiCepat didirikan pada tahun 2004 oleh Rudy Darwin Swigo dan The Kim Hai pada awalnya bergerak dibidang ekspedisi dan kargo. Hingga saat ini, SiCepat telah memiliki 730 cabang yang tersebar di seluruh Indonesia. Perusahaan ini mengalami pertumbuhan yang pesat, khususnya sejak tahun 2015, karena

melakukan kerja sama secara langsung dengan beberapa *e-commerce* besar di Indonesia antara lain Tokopedia, JakMall, Lazada, Blibli.com, dan lain-lain (PT. SiCepat Ekspres Indonesia, 2020).

2.2 Kebijakan Terkait Penanganan Pandemi

Dalam upaya penanganan wabah covid-19 yang telah terdeteksi penyebarannya dari pasien pertama sejak 2 Maret 2020, pada tanggal 31 Maret 2020, Presiden Republik Indonesia, Joko Widodo, telah mengesahkan Peraturan Pemerintah Nomor 21 Tahun 2020 dan Keputusan Presiden Nomor 11 Tahun 2020. Peraturan Pemerintah Nomor 21 dibuat untuk memberikan dasar hukum penerapan pembatasan sosial berskala besar dalam rangka percepatan penanganan pandemi, sedangkan Keputusan Presiden Nomor 11 Tahun 2020 menyatakan bahwa pandemi covid-19 merupakan keadaan darurat kesehatan dan menetapkannya sebagai bencana nasional di Indonesia.

Dengan disahkannya Peraturan Pemerintah Nomor 21 Tahun 2020, pemerintah daerah memiliki kewenangan untuk membatasi pergerakan orang maupun keluar masuk barang dari/ke daerah masing-masing. Namun demikian kebijakan pembatasan yang dilakukan oleh pemerintah daerah tersebut harus telah dikoordinasikan dengan Kementerian Kesehatan. Dalam peraturan ini disebutkan bahwa pembatasan kegiatan yang dilakukan minimal meliputi meliburkan sekolah dan tempat kerja, pembatasan kegiatan keagamaan, serta pembatasan kegiatan di tempat/fasilitas umum lainnya.

Daerah-daerah yang telah menetapkan kebijakan pembatasan sosial skala besar antara lain DKI Jakarta pada 10 April 2020 dan berlanjut pada daerah-daerah penyangga Ibu Kota seperti kabupaten dan kota Bogor, kabupaten dan kota Bekasi, dan kota Depok pada 15 April 2020 serta wilayah Bandung Raya di hari yang sama. Kebijakan pembatasan selanjutnya ditetapkan di daerah/kota lain di Indonesia seperti wilayah Tangerang, Pekanbaru, provinsi Sumatera Barat, Makassar, Surabaya, dan daerah lainnya (Mashabi & Galih, 2020).

Berkaitan dengan kebutuhan kemanusiaan, setidaknya sepuluh (10) sektor usaha tetap dapat beroperasi selama pembatasan sosial skala besar yaitu sektor kesehatan, sektor pangan (makanan dan minuman), sektor energi, sektor komunikasi, teknologi dan informasi, sektor keuangan dan perbankan, sektor logistik dan distribusi barang, sektor konstruksi, sektor industri strategis, sektor dasar dan utilitas publik, dan sektor retail yang

melayani kebutuhan sehari-hari (Defianti, 2020). Dengan adanya pengecualian ini diharapkan operasional sektor usaha tersebut tidak mengalami gangguan selama kebijakan-kebijakan terkait penanganan pandemi diterapkan.

2.3 Sosial Media Twitter

Twitter merupakan salah satu jenis media sosial *microblogging* atau pesan singkat yang saat ini banyak digunakan untuk berkomunikasi, mengungkapkan isi hati, dan berbagi informasi. Jenis media sosial *microblogging* menjadi populer dan disukai di Indonesia, karena mudah dipahami terutama bagi masyarakat yang tidak suka membaca tulisan atau artikel yang terlalu panjang.

Berdasarkan pengamatan, lebih dari 68% pengguna media sosial secara langsung akan melihat profil akun media sosial penyedia produk/layanan dan mencari rekomendasi berdasarkan ulasan pelanggan lain sebelum memutuskan untuk melakukan transaksi bisnis (SF Media Solutions - Web Design and Online Marketing, 2017). Hal ini terjadi karena saat ini membaca ulasan pelanggan lain merupakan salah satu bagian dalam pengambilan keputusan dimana data menyebutkan 77% menyempatkan diri untuk membaca ulasan pelanggan ini. Ulasan yang ditulis oleh pelanggan lain secara *on-line* cenderung lebih dapat dipercaya karena bersifat lebih personal, 88% pengguna lebih mempercayai ulasan melalui media sosial dibandingkan platform lain. Dan terpenting, informasi yang didapat dari media sosial adalah gratis.

Sebagai media sosial *microblog*, pesan dalam Twitter memiliki jumlah karakter yang terbatas. Pesan dalam Twitter hanya dapat memuat maksimal 140 karakter dimana pesan tersebut dapat bisa berisi pesan teks, *emoji*, tautan ke alamat web tertentu, *mention* (@), *hashtag* (#), maupun konten grafis berukuran kecil dan sederhana. *Mention* (@) dalam Twitter berarti menyebutkan pengguna (akun) lain dalam pesan yang kita buat, sedangkan *hashtag* (#) berarti pesan yang ditulis terhubung dengan suatu topik tertentu.

Karena terbatasnya jumlah karakter yang dapat ditulis dalam pesan Twitter, kebanyakan pengguna memakai tata bahasa maupun penulisan yang tidak baku, seperti kata yang disingkat (seperti: 'untk' yang berarti 'untuk'), menghilangkan huruf vokal (seperti: 'dgn' yang berarti 'dengan'), mengganti kata berulang dengan angkat (seperti: 'sama2' yang berarti 'sama-sama'), penyertaan *emoji*, dan lain-lain. Banyaknya penggunaan tata bahasa tidak baku dalam Twitter merupakan tantangan tersendiri dalam analisis teks karena

dalam penafsiran kata maupun singkatan mengharuskan peneliti untuk melihat konteks pembicaraan. Oleh sebab itu, tahap *preprocessing* terhadap data yang telah berhasil dikumpulkan merupakan tahapan paling penting dan menentukan dalam analisis teks khususnya data-data yang tidak terstruktur seperti data yang didapatkan dari media sosial Twitter (Miner, et al., 2012).

2.3.1 Pengguna Twitter di Indonesia

Pengguna media sosial di Indonesia terus bertambah setiap tahunnya. Kemp (2021) menyebutkan bahwa pada tahun 2021 jumlah pengguna media sosial mencapai 170 juta orang atau 61,8% dari total jumlah penduduk Indonesia. Hal ini berarti bahwa telah terjadi peningkatan jumlah pengguna Twitter sebesar 6,3% bila dibandingkan dengan jumlah pengguna media sosial pada periode yang sama pada tahun 2020. Dari jumlah pengguna media sosial tersebut 63,6% diantaranya merupakan pengguna aktif media sosial Twitter yang terdiri dari 43,9% perempuan dan 56,1% adalah laki-laki. Pengguna Twitter di Indonesia dapat menghabiskan waktu rata-rata waktu mencapai 8,1 jam tiap bulannya. Mayoritas pengguna Twitter di Indonesia adalah konsumen yaitu pengguna yang tidak memiliki *blog* atau tidak pernah mengunggah video atau konten lain namun sering memperbaharui status di akun media sosialnya (Kominfo, 2013).

2.3.2 Twitter Sebagai Pusat Pengaduan dan Layanan Pelanggan

Twitter sebagai salah satu media sosial terbesar memberi keuntungan tersendiri baik bagi penyedia suatu layanan maupun pengguna. Bagi penyedia layanan, kehadiran media sosial Twitter memberikan keuntungan dimana penyedia layanan tidak perlu menyiapkan platform pusat pengaduan dan layanan pelanggan secara mandiri yang tentu saja membutuhkan biaya yang tidak sedikit. Sedangkan bagi pengguna, adanya layanan pelanggan tersebut memudahkan dalam memberikan masukan, pendapat, hingga keluhan terkait layanan yang diterimanya.

Penelitian ini memanfaatkan akun-akun resmi yang dipergunakan penyedia layanan sebagai pusat pengaduan dan layanan pelanggan, yaitu @JNE_ID dan @JNECare untuk JNE, @jntexpressid untuk J&T, @PosIndonesia untuk Pos Indonesia, @TIKICare dan @IdTiki untuk TIKI, dan @sicepat_ekspres untuk SiCepat.

2.4 Text Mining

Text mining merupakan gabungan dari beberapa komponen analisis teks, adalah proses pengolahan data teks (*semistructured* dan *unstructure*) dalam jumlah besar dan mengubahnya ke dalam bentuk terstruktur dalam format numerik untuk mendapatkan informasi yang terkandung di dalamnya dengan mengaplikasikan algoritma-algoritma yang sesuai. *Text mining* setidaknya memiliki tiga tujuan utama antara lain *information retrieval*, *information extraction*, dan *summarization* (Miner, et al., 2012). *Information retrieval* digunakan untuk menemukan kembali informasi-informasi yang relevan bagi pengguna sesuai dengan kata kunci atau bagian kalimat suatu teks.

Information extraction yaitu proses analisis teks yang memiliki tujuan untuk mengambil informasi spesifik dari suatu sekumpulan besar data seperti mengetahui tren, klusterisasi dan klasifikasi teks, maupun kebutuhan data lainnya. Selanjutnya *summarization* yaitu proses analisis teks yang bertujuan untuk memperoleh informasi utama dalam data teks atau dokumen seperti membuat abstrak suatu dokumen secara otomatis hingga pemodelan topik.

2.5 Analisis Teks

Berdasarkan tujuan yang ingin dicapai, fokus, ketersediaan data, algoritma yang digunakan, dan sumber data yang dimiliki, analisis teks dapat dibagi menjadi tujuh (7) komponen utama (Miner, et al., 2012), yaitu:

1. *Search and information retrieval*: Analisis teks ini biasa diaplikasikan sebagai search engine atau mesin pencari. Google, Yahoo, dan Bing adalah mesin pencari di internet populer yang merupakan contoh aplikasi *search and information retrieval*.
2. *Document clustering*: Analisis teks ini memiliki tujuan mengelompokkan teks berdasarkan kemiripan sesuai dengan algoritma metode *clustering (unsupervised)* yang dipergunakan pada data mining.
3. *Document classification*: Analisis teks ini memiliki tujuan mengelompokkan teks menggunakan metode klasifikasi (*supervised*) seperti data mining, berdasarkan model yang telah dilatih menggunakan data sampel.
4. *Web mining*: Analisis teks ini memiliki fokus pengambilan dan pengolahan data teks yang ada di halaman web. Metode yang umum dipergunakan dalam web

mining adalah *web crawling* dan *web scraping*. *Web crawling* adalah proses pengambilan data dari internet berdasarkan tautan dan memerlukan jalur komunikasi khusus, sedangkan *web scraping* merupakan proses pengambilan data di internet berdasarkan metode ekstraksi konten sebuah website.

5. *Information extraction*: Identifikasi dan ekstraksi informasi data teks tidak terstruktur atau semi terstruktur menjadi data terstruktur.
6. *Natural language processing*: Analisis teks ini merupakan proses sinkronisasi algoritma, normalisasi teks agar sesuai dengan pemahaman bahasa manusia.
7. *Concept extraction*: Analisis teks ini bertujuan mengelompokkan kata atau kalimat yang memiliki kemiripan makna.

Dalam analisis teks, umumnya terdiri dari beberapa komponen utama dalam proses analisisnya.

2.6 Analisis Sentimen

Analisis sentimen atau biasa disebut juga dengan nama *opinion mining* adalah bidang ilmu yang mempelajari opini, penilaian, persetujuan, sikap, hingga emosi seseorang akan suatu objek/topik permasalahan (Liu, 2015). Objek/topik permasalahan tersebut dapat berupa kepuasan terhadap kualitas suatu produk maupun layanan, penerimaan akan suatu kebijakan, pendapat mengenai isu-isu yang bersifat spesifik, dan lain-lain. Dalam konteks pada layanan jasa, sentimen positif dapat diartikan bahwa seseorang memiliki pandangan bahwa suatu layanan telah memenuhi harapan dari orang yang bersangkutan, atau sebaliknya sentimen negatif dapat diartikan bahwa seseorang memiliki pandangan bahwa layanan tidak sesuai seperti yang diharapkan. Sentimen negatif atau *Negative Word Of Mouth* (NWOM) adalah respons konsumen terhadap ketidakpuasan akan kualitas layanan maupun produk yang diterimanya (Richins, 1984).

Saat ini analisis sentimen semakin banyak dipergunakan di berbagai bidang seperti kesehatan, pariwisata, pengembangan dan evaluasi produk dan jasa, finansial, hingga politik dan dapat dipergunakan baik oleh individu, organisasi, maupun pemerintah. Dengan adanya analisis sentimen, cara-cara lama dalam memperoleh opini/pendapat publik seperti pengisian survei, kuesioner, jajak pendapat, dan *focus group* secara teknis sudah tidak diperlukan lagi (Liu, 2015). Selain itu, opini lebih cepat diperoleh karena memanfaatkan data yang sudah tersedia yang umumnya berasal dari media sosial.

Dilihat dari sisi tujuan dan fokusnya, analisis sentimen sendiri termasuk dalam kategori *document classification* dan *concept extraction*, dimana analisis sentimen memiliki tujuan mengklasifikasikan teks berdasarkan kata atau gabungan kata yang memiliki kemiripan nilai sentimen. Sedangkan dari sisi sumber dan bentuk data yang digunakan, sentimen analisis terhadap data percakapan di Twitter memerlukan tahapan proses *web mining*, *information extraction*, dan *Natural Language Processing* (NLP) dimana dalam proses mendapatkan data hingga data tersebut siap digunakan dalam analisis harus melalui tahapan-tahapan tersebut. Dalam analisis sentimen, kata yang dapat dijadikan ciri dalam proses klasifikasi biasa disebut dengan fitur (*feature*), sehingga kata yang memiliki nilai sentimenlah menjadi pertimbangan dalam proses ekstraksi fitur.

2.6.1 Analisis Sentimen Jendela Waktu

Untuk mengetahui pengaruh peristiwa pada entitas tertentu atau untuk menganalisis tren melalui analisis sentimen, peneliti menggunakan pendekatan jendela waktu (*time window*) untuk mendeteksi tanggapan pengguna media sosial terhadap suatu peristiwa. Analisis sentimen jendela waktu menggunakan satuan waktu sebagai dasar pengambilan sampel teks dan menganalisisnya berdasarkan waktu yang telah ditentukan tersebut. Analisis sentimen jendela waktu dapat mengidentifikasi waktu kritis atau peristiwa secara efektif (Wang, Wu, Zhang, & Zhu, 2020). Analisis sentimen jendela waktu tidak hanya efektif untuk mengidentifikasi waktu atau peristiwa kritis, tetapi juga dapat digunakan untuk prediksi atau tugas peramalan, seperti prediksi harga saham yaitu dengan mengkorelasikan tren harga saat ini dengan tren sentimen yang ada dalam diskusi Twitter (Rao & Srivastava, 2012). Analisis sentimen jendela waktu juga dapat digunakan untuk menganalisis dan memprediksi tren sentimen pengguna tertentu berdasarkan data historis dan dapat diterapkan dalam kondisi waktu nyata (Yoo, Song, & Jeong, 2018).

2.6.2 Ekstraksi Fitur dalam Sentimen Analisis

Ekstraksi fitur dalam analisis sentimen merupakan proses pemilihan kata dari data teks yang dapat dijadikan ciri dalam proses klasifikasi sentimen. Sebuah kata yang dijadikan fitur harus memiliki keunikan sehingga dapat digunakan untuk menggambarkan nilai/sentimen dari teks yang diwakilinya. Dalam analisis sentimen dan klasifikasi teks secara umum, proses ekstraksi fitur merupakan proses penting dan menentukan kualitas hasil analisis secara keseluruhan. Tahapan ini penting karena dalam proses ini sebuah

kata akan dinilai apakah kata tersebut dapat dipergunakan dalam proses klasifikasi atau harus dibuang karena tidak memiliki makna.

Dalam klasifikasi teks termasuk sentimen analisis, terdapat dua (2) pendekatan metode yang dapat dipergunakan dalam proses ekstraksi fitur. Kedua pendekatan tersebut yaitu: pendekatan leksikal yang biasa disebut juga dengan *rule based method* atau *semantic based method* dan pendekatan statistik atau *statistical based method*. Kedua pendekatan ini memiliki algoritma dan metode yang berbeda dimana ekstraksi fitur pada pendekatan leksikal memanfaatkan sumber leksikal (*lexical resouce*) dalam proses ekstraksi sedangkan pendekatan statistik memanfaatkan perhitungan matematis dalam menilai tingkat kepentingan suatu kata berdasarkan frekuensi kemunculannya dalam sebuah data teks.

Analisis sentimen dengan ekstraksi fitur metode leksikal dan statistik pada data teks yang sama memberikan performa sedikit berbeda, dimana metode statistik memberikan performa yang dinilai dari skor akurasi, presisi, *recall* dan *f-score* lebih tinggi (3-4%). Namun demikian dari keseluruhan pengujian menggunakan berbagai metode klasifikasi, kedua pendekatan ekstraksi fitur tidak memberikan perbedaan performa yang signifikan (Ahuja, Chug, Kohli, Gupta, & Ahuja, 2019).

2.6.2.1 Pendekatan Leksikal

Pada pendekatan leksikal, proses ekstraksi fitur memanfaatkan makna kata dalam data teks. Dalam pendekatan leksikal, sumber leksikal memiliki peranan yang sangat penting dalam menentukan skor sentimen sebuah kalimat untuk dapat dikelompokkan dalam klasifikasi positif, negatif, atau netral. Meskipun terlihat sederhana, pada praktiknya pendekatan leksikal menghadapi beberapa masalah yang sulit diatasi hingga saat ini (Liu, 2015). Masalah-masalah tersebut antara lain:

1. Polaritas sentimen suatu opini atau pendapat dapat memiliki orientasi yang berbeda bahkan berbalik pada konteks dan situasi yang berbeda.
2. Kata yang memiliki nilai sentimen terkadang tidak mengandung sentimen apapun dalam kalimat tertentu. Contoh: 'terima kasih atas bantuannya' mengandung sentimen positif tetapi pada kalimat 'mohon informasinya, terima kasih' cenderung tidak memiliki sentimen apapun.

3. Kalimat sarkasme sulit untuk dideteksi tanpa mengetahui konteksnya, namun demikian kalimat sarkasme jarang dijumpai pada *review* produk atau layanan. Contoh: ‘Profesionalnya kelewatan, barang bisa sampai hancur’
4. Memerlukan campur tangan peneliti dalam menentukan sentimen sebuah kalimat ketika kalimat tersebut tidak mengandung kata sentimen. Contoh: ‘Adminnya tidur’ sejatinya kalimat netral, tetapi dalam konteks layanan pelanggan kalimat tersebut dapat memiliki sentimen negatif.

Selain itu, dalam pendekatan leksikal harus juga memperhatikan kalimat yang mengandung kata negasi, karena kata yang terletak sesudah kata negasi memiliki sentimen yang bertolak belakang. Kata negasi dalam bahasa Indonesia meliputi kata ‘tidak’, ‘belum’, ‘bukan’, dan ‘tanpa’. Contoh: kata ‘pandai’ yang memiliki sentimen positif apabila terletak setelah kata negasi ‘tidak’ menjadi kata ‘tidak pandai’ yang berarti sebaliknya yaitu sama dengan ‘bodoh’.

Sumber leksikal adalah kata rujukan yang telah memiliki skor sentimen yang dipergunakan dalam memberikan klasifikasi terhadap kalimat atau teks secara keseluruhan. Sumber leksikal dapat dibuat dengan tiga (3) pendekatan, yaitu

1. Penyusunan sumber leksikon secara manual.
2. Penyusunan sumber leksikon atau pelabelan data teks berdasarkan translasi kata dalam kamus leksikon bahasa lain (contoh bahasa Inggris: SentiWordNet, TextBlob) dan memberikan nilai skor kata translasi tersebut sesuai dengan bahasa asalnya.
3. Penyusunan sumber leksikon berdasarkan benih kata (*corpus*) sentimen yang pada umumnya memiliki orientasi tetap ketika dihadapkan pada konteks yang berbeda atau mengadaptasi sumber leksikon yang ada yang disesuaikan dengan kondisi dan konteks penelitian kita.

Sentimen leksikon berbahasa Indonesia saat ini masih memiliki sumber leksikon yang sangat terbatas. Berbeda dengan sentimen leksikon Inggris yang sudah matang dan lengkap, sentimen leksikon berbahasa Indonesia sehingga masih memerlukan banyak pengembangan dan belum sepenuhnya dapat diandalkan. Hal ini menyebabkan proses klasifikasinya memerlukan evaluasi manual dari peneliti untuk mendapatkan hasil yang maksimal.

Vania, Ibrahim, & Adriani (2014) menggunakan metode pendekatan benih kata (*seed corpus*) yang berjumlah 291 kata bersentimen negatif dan 517 kata bersentimen positif untuk menyusun sumber leksikon yang lebih besar. Dari benih kata bersentimen tersebut dapat diturunkan menjadi sumber leksikon untuk data Twitter sebesar 3,381 kata bersentimen negatif dan 8,435 kata bersentimen positif.

Koto & Rahmaningtyas (2017) membuat sumber leksikon yang diberi label dan nilai sentimen secara manual. Jangkauan nilai yang dipergunakan adalah -5 hingga +5, dimana nilai -5 merupakan nilai sentimen paling negatif yang pada umumnya berupa kata sumpah-serapah dan kata tidak sopan lainnya sedangkan nilai +5 merupakan nilai paling positif seperti kata 'cinta', 'gembira', 'setia', dan seterusnya. Sumber leksikon yang berhasil dibuat tersebut memiliki total 3,609 kata bersentimen positif dan 6,609 kata bersentimen negatif. Berdasarkan hasil evaluasi dengan menggunakan empat (4) metode klasifikasi yang berbeda, sumber leksikon ini memiliki performa akurasi yang lebih baik bila dibandingkan dengan hasil evaluasi sumber leksikon yang disusun Vania, Ibrahim, & Adriani, maupun ekstraksi fitur yang didapatkan dengan metode translasi dari kamus leksikon bahasa asing seperti SentiWordNet dan Liu leksikon.

Pada penelitian ini menggunakan sumber leksikon yang telah disusun oleh Koto & Rahmaningtyas. Sumber leksikon yang disusun oleh Koto & Rahmaningtyas bersifat umum sehingga perlu dilakukan optimasi dan adaptasi. Optimasi dilakukan dengan pemilihan kata dalam sumber leksikon yang juga terdapat dalam data yang dianalisis. Sedangkan adaptasi diperlukan untuk mengevaluasi klasifikasi yang diperoleh agar sesuai dengan konteks penelitian. Proses pendekatan leksikal disini dipergunakan pada klasifikasi model, dengan tujuan untuk mendapatkan konsistensi klasifikasi yang lebih baik jika dibandingkan dengan pelabelan secara manual.

2.6.2.2 Pendekatan Statistik

Ekstraksi fitur melalui pendekatan statistik dilakukan dengan perhitungan matematis yaitu menilai tingkat kepentingan suatu kata berdasarkan frekuensi kemunculannya dalam sebuah data teks. Algoritma yang umum dipergunakan dalam pendekatan statistik yaitu *Term Frequency (TF)* dan *Term Frequency – Invers Document Frequency (TF-IDF)*. Dalam algoritma TF, kata yang sering muncul menjadi fitur yang mewakili data yang dianalisis. Sedangkan dalam TF-IDF, kata yang menjadi fitur sebuah dokumen atau

data adalah kata yang sering muncul dalam kalimat, tetapi tidak sering muncul dalam keseluruhan dokumen. Kata yang sering muncul dalam kalimat maupun dalam keseluruhan dokumen dianggap kata yang bersifat umum.

Nilai TF dihitung dari jumlah kemunculan suatu kata (t) dalam dokumen (d) dibandingkan dengan jumlah kata dalam dokumen tersebut. Sedangkan nilai IDF didapatkan dari perhitungan logaritmik jumlah total dokumen dibandingkan dengan jumlah dokumen yang mengandung kata (t) tersebut. Nilai TF-IDF didapatkan dari hasil perkalian nilai TF dan nilai IDF. Persamaan matematis untuk perhitungan TF-IDF ini dapat dilihat pada persamaan berikut:

$$tf.idf(t, d) = tf(t, d).idf(t) \quad (2.1)$$

Dengan:

$$tf(t, d) = \sum_{i \in d}^{|d|} 1\{d_i = t\}$$

$$idf(t) = \log \left[\frac{|D|}{\sum_{d \in D}^{|D|} 1\{t \in d\}} \right]$$

Dimana:

tf = term frequency

idf = invers term frequency

t = kata

d = dokumen/kalimat

D = keseluruhan dokumen/kalimat

Contoh perhitungan TF-IDF pada suatu kalimat yang memiliki panjang 100 kata dimana dalam kalimat tersebut mengandung kata 'lambat' muncul 3 kali. Maka nilai TF untuk kata 'lambat' adalah $3/100 = 0,03$. Jika keseluruhan data terdapat memiliki 10 juta kalimat dan kata 'lambat' muncul dalam 1.000 kalimat, maka nilai IDF adalah $\log(10 \text{ juta}/1000) = 4$. Sehingga hasil perhitungan TF-IDF untuk kata 'lambat' adalah $0,03 * 4 = 0,12$.

2.6.3 Data Preprocessing

Data *preprocessing* merupakan tahapan wajib hampir pada semua analisis karena data yang didapatkan dalam analisis teks pada umumnya memiliki karakteristik semi

terstruktur atau sepenuhnya tidak terstruktur. Tahapan ini memiliki tujuan untuk menstrukturkan data-data tersebut sehingga dapat dianalisis lebih lanjut menggunakan metode-metode atau algoritma yang sesuai. Beberapa langkah utama yang ada dalam tahapan *preprocessing* antara lain:

1. *Normalize case*: kata dalam dokumen secara umum dapat ditulis baik dengan menggunakan huruf besar, huruf kecil, maupun kombinasi keduanya sesuai dengan kaidah penulisan. Hal ini digunakan untuk membedakan antara kalimat satu dengan lainnya atau tanda dimulainya kalimat baru, penulisan nama, singkatan, dan lain sebagainya. Langkah *normalize case* memiliki tugas mengubah semua kata –kata ini ke dalam huruf besar atau huruf kecil. Hal ini dilakukan karena kata-kata yang memiliki huruf besar memiliki arti yang sama dengan kata yang tidak memiliki huruf besar. Contoh kata pada awal kalimat memiliki arti yang sama jika kata tersebut berada pada posisi lain dalam kalimat.
2. *Data cleansing*: Langkah ini memiliki fungsi untuk menghilangkan tanda baca, simbol-simbol seperti *hashtag* (#) dan *mention* (@), spasi berlebih, angka, tautan ke alamat *website*, *emoji*, bagian kata yang ditulis berulang, kata yang hanya terdiri dari satu huruf, dan membuang kalimat yang hanya terdiri dari satu kata.
3. *Tokenization*: Langkah pada tahapan *preprocessing* ini memiliki fungsi memecah kalimat ke dalam bentuk kata individual. Proses ini dilakukan dengan menambahkan pembatas untuk setiap kata dengan spasi atau tanda petik. Pemecahan kalimat ke dalam bentuk kata secara individual diperlukan untuk proses langkah selanjutnya seperti *normalize spelling*, *stopword removal*, dan *stemming*, karena langkah ini dikerjakan kata demi kata.
4. *Normalize spelling*: Langkah ini memiliki tugas mengubah kata yang tidak baku menjadi kata-kata baku sesuai dengan Kamus Besar Bahasa Indonesia (KBBI) atau kata-kata yang merupakan sinonim diseragamkan dalam satu kata yang sama. Proses ini memerlukan waktu dan tenaga paling besar dari semua tahapan *preprocessing* karena mengharuskan peneliti membuat daftar kata tidak baku termasuk kata yang disingkat menjadi kata baku secara manual.
5. *Stopword removal*: Langkah ini memiliki fungsi menghilangkan kata-kata yang tidak memiliki makna. Daftar kata-kata yang termasuk dalam *stopword* bahasa

Indonesia telah tersedia dalam pustaka *Natural Language Processing Kit (NLTK)* Python.

6. *Stemming*: Langkah ini berfungsi untuk mengubah kata-kata yang memiliki imbuhan termasuk awalan, sisipan, dan akhiran kata ke dalam bentuk dasarnya. Pustaka Python Sastrawi dipergunakan pada langkah ini. Python Sastrawi merupakan pustaka *stemming* Python untuk bahasa Indonesia yang dibuat berdasarkan algoritma yang ditulis oleh Adriani, Asian, Nazief, Tahaghoghi, & Williams (2007).

2.6.4 Klasifikasi

Klasifikasi adalah proses untuk mengelompokkan data yang satu dengan yang lain menggunakan metode-metode yang sesuai dengan memprediksi kelompok dari data yang belum diketahui keanggotaannya berdasarkan karakter unik yang dimiliki oleh data tersebut sebagai sumber penilaian. Dalam analisis teks, termasuk analisis sentimen dan juga pemodelan topik, kata-kata unik yang menjadi fitur dokumenlah yang menjadi pedoman dalam mengklasifikasi kelompok dokumen tersebut.

Metode klasifikasi dalam analisis teks secara garis besar dibedakan menjadi dua kelompok, yaitu *rule based classification method* dan *statistical based classification method* atau biasa disebut dengan istilah *machine learning classification method*.

2.6.4.1 Rule Based Classification Method

Rule based classification method merupakan metode klasifikasi data yang menggunakan koleksi aturan (*rule*) kondisi ‘jika (kondisi terpenuhi), maka (tujuan yang dipakai)’.

Analisis sentimen dengan pendekatan leksikal pada umumnya menggunakan metode klasifikasi ini, dimana setelah sebuah teks memiliki nilai sentimen (diperoleh pada tahap ekstraksi fitur), maka teks tersebut akan dikelompokkan menjadi ‘Positif’, ‘Negatif’, atau ‘Netral’ berdasarkan aturan sebagai berikut:

- Jika skor sentimen yang dimiliki sebuah teks adalah lebih besar dari nol (> 0), maka teks tersebut masuk dalam klasifikasi sentimen ‘Positif’.
- Jika skor sentimen yang dimiliki sebuah teks adalah sama dengan nol ($= 0$), maka teks tersebut masuk dalam klasifikasi sentimen ‘Netral’.
- Jika skor sentimen yang dimiliki sebuah teks adalah kurang dari nol (< 0), maka teks tersebut masuk dalam klasifikasi sentimen ‘Negatif’.

Proses klasifikasi sentimen untuk pelabelan data latih dalam penelitian ini sendiri menggunakan pendekatan *rule based classification*.

2.6.4.2 *Statistical Based Classification*

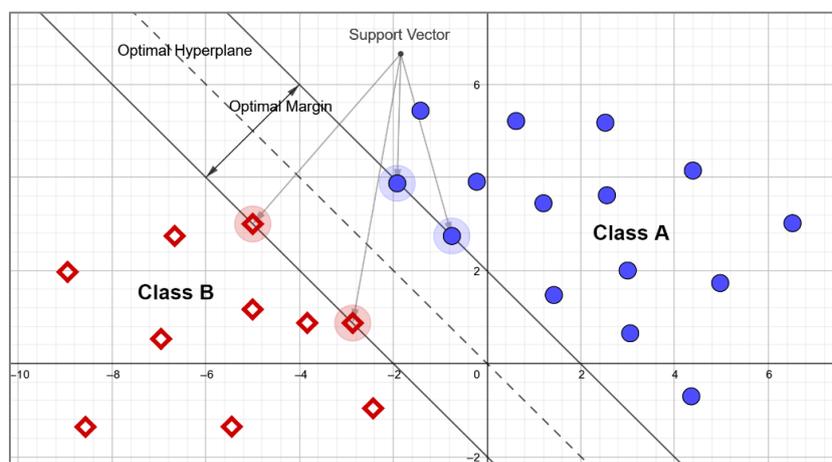
Statistical based classification method memanfaatkan perhitungan matematis untuk memisahkan data sesuai kelas masing-masing atau biasa disebut dengan *machine learning*. *Statistical based classification* merupakan metode yang sangat populer dan telah banyak digunakan dalam penelitian berbasis klasifikasi teks, termasuk pada analisis sentimen.

Dalam beberapa penelitian memperlihatkan bahwa klasifikasi data dengan *statistical based classification* memiliki performa yang lebih baik dibandingkan dengan *rule based classification* seperti yang terjadi pada penelitian Khoo & Johnkhan (2017). Penelitian ini menunjukkan bahwa performa klasifikasi dengan pendekatan statistik memiliki hingga 10% lebih baik bila dibandingkan dengan pendekatan aturan. Namun demikian klasifikasi pendekatan statistik memerlukan data latih dalam pembuatan model klasifikasinya, sehingga pendekatan *rule based* sering kali dipergunakan terutama dalam proses klasifikasi data latih ini.

Pendekatan statistik yang populer dan sering digunakan dalam mengklasifikasi baik dalam untuk teks maupun *data mining* secara umum antara lain *Support Vector Machine* (SVM), *Naïve Bayes* (NB), *K-Nearest Neighbor* (KNN), dan *Random Forest* (RF). Dalam hal ini, SVM merupakan metode yang paling sering dipergunakan karena metode ini memiliki konsep dan algoritma yang lebih matang jika dibandingkan dengan metode klasifikasi yang lain. Beberapa alasan metode SVM menjadi begitu populer antara lain karena dapat menangani data dalam jumlah besar dan sesuai untuk regresi linier maupun non-linier (Vijayarani & Dhayanand, 2015).

Metode SVM pertama kali diperkenalkan oleh Boser, Guyon, & Vapnik (1992), dimana metode SVM termasuk dalam konsep unggulan dalam *patern recognition* yang saat ini telah berkembang dengan sangat pesat dan diaplikasikan dalam berbagai bidang. Adapun menurut Nugroho, Witarto, & Handoko (2003), metode SVM memiliki beberapa keuntungan diantaranya adalah (1) kemampuan generalisasi (mengklasifikasi data baru), (2) mampu mengatasi masalah *curse of dimentionalty* (mempergunakan jumlah data lebih sedikit dari populasi data sebenarnya), dan (3) feasibilitas dimana metode ini relatif

lebih mudah diimplementasikan. Adapun cara kerja metode klasifikasi SVM diilustrasikan pada Gambar 2.1, dimana SVM mencari *hyperplane* (bidang pembatas) terbaik dengan memaksimalkan jarak (*margin*) antar kelas.



Gambar 2.1. Ilustrasi cara kerja SVM

Penelitian Rus, Annisa, Surjandari, dan Zulkarnain (2019) menggunakan tiga metode pendekatan statistik yang berbeda untuk perbandingan yaitu SVM, NBC dan k-NN. Penelitian ini memberikan sentimen positif hampir di keseluruhan dimensi kualitas layanan (*Employee, Facility, Reliability, Room, Surrounding*). Adapun berdasarkan penelitian ini membuktikan bahwa metode SVM memiliki performa yang terbaik dibandingkan metode lainnya. Hasil perbandingan ini juga didukung oleh penelitian Tuhuteru & Iriani (2018), di mana metode SVM memiliki lebih baik dibandingkan dengan NBC.

Analisis sentimen yang dilakukan oleh Zulkarnain, Surjandari, & Wayasti (2018) pada layanan jasa transportasi berbasis *on-line* platform dengan pendekatan statistik SVM juga memberikan hasil akurasi klasifikasi yang sangat baik yaitu 86%. Adapun data latih yang dipergunakan untuk pembuatan model diklasifikasi secara manual.

Dari beberapa metode klasifikasi yang ada melalui pendekatan statistik, pada penelitian-penelitian sebelumnya metode SVM telah memberikan hasil klasifikasi yang lebih baik dibandingkan metode-metode lain. Dengan pertimbangan tersebut, klasifikasi dengan pendekatan statistik SVM dipergunakan dalam penelitian ini untuk mengklasifikasi keseluruhan data berdasarkan data latih yang diperoleh dari pendekatan leksikal.

2.6.5 Pengujian dan Validasi

Tahapan pengujian dan validasi bertujuan untuk mengukur performa metode klasifikasi yang digunakan dalam pembuatan model. Pengujian dan validasi ini dilakukan dengan mengukur nilai dari parameter akurasi (*accuracy*), presisi (*precision*), *recall*, dan *f1-score*. Adapun perhitungan nilai akurasi, presisi, *recall*, maupun *f1-score* dapat menggunakan *confussion matrix* seperti yang ditunjukkan pada Tabel 2.1.

Tabel 2.1. *Confussion matrix*

| | | Kelas Prediksi | |
|------------------|----------|------------------------|------------------------|
| | | Positive | Negative |
| Kelas Sebenarnya | Positive | TP (True Positive) | FP (False Positive) |
| | Negative | FN (False Negative) | TN (True Negative) |

Dalam *confussion matrix* terdapat empat (4) status yang mewakili hasil prediksi metode klasifikasi, yaitu:

1. *TP / True Positive*, data sebenarnya ‘Positif’ dan hasil prediksi ‘Positif’.
2. *FP / False Positive*, data sebenarnya ‘Positif’ dan hasil prediksi ‘Negatif’.
3. *FN / False Negative*, data sebenarnya ‘Negatif’ dan hasil prediksi ‘Positif’.
4. *TN / True Negative*, data sebenarnya ‘Negatif’ dan hasil prediksi ‘Negatif’.

Akurasi adalah menghitung jumlah data prediksi yang sesuai dengan kelas sebenarnya pada data latih yang kemudian dibandingkan dengan jumlah keseluruhan data pengujian. Dalam pengukuran akurasi, semakin tinggi nilai akurasi sebuah pengujian, maka dapat disimpulkan bahwa metode yang dipergunakan dalam analisis tersebut telah sesuai dengan karakteristik data yang dimiliki terutama fitur yang dipergunakan. Perhitungan nilai akurasi dapat dilihat pada Persamaan 2.2.

$$Accuracy = \frac{TP+TN}{Overall\ Data} \quad (2.2)$$

Presisi adalah rasio jumlah data prediksi yang sesuai dengan kelas sebenarnya dibandingkan dengan jumlah data untuk prediksi yang sama. Contoh perhitungan nilai presisi untuk kelas ‘Positif’ dapat dilihat pada Persamaan 2.3.

$$Precision\ for\ Positive\ Prediction = \frac{TP}{TP+FN} \quad (2.3)$$

Recall adalah rasio jumlah data prediksi yang sesuai dengan kelas sebenarnya dibandingkan dengan jumlah data sebenarnya untuk kelas yang sama. Contoh perhitungan nilai *recall* untuk kelas ‘Positif’ dapat dilihat pada Persamaan 2.4.

$$\text{Recall for Positive Prediction} = \frac{TP}{TP+FP} \quad (2.4)$$

f1-score adalah merupakan nilai pembobotan antara nilai presisi dan *recall*, dimana pengukuran ini menunjukkan nilai rata-rata kedua parameter tersebut. Perhitungan nilai *f1-score* secara umum dapat dilihat pada Persamaan 2.5.

$$f1_score = \frac{2*(Recall*Precision)}{Recall+Precision} \quad (2.5)$$

Metode *k-fold cross validation* dipergunakan dalam tahap evaluasi model untuk melihat konsistensi dari model SVM yang dibentuk sebelum dipergunakan untuk mengklasifikasi keseluruhan data. *10-fold cross validation* merupakan salah satu nilai *k* yang direkomendasikan dalam proses validasi model karena memberikan hasil estimasi yang baik. Dalam *10-fold cross validation*, data dibagi menjadi 10 bagian yang sama atau setara seperti ditunjukkan pada Tabel 2.2, sehingga terbentuk 10 kombinasi *sub-set* data yang kemudian dihitung akurasi pada masing-masing *sub-set* tersebut.

Tabel 2.2. Ilustrasi pembagian *sub-set* data pada *10-fold cross validation*

| | | | | | | | | | | |
|-----------|---|---|---|---|---|---|---|---|---|----|
| subset 1 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 |
| subset 2 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 |
| subset 3 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 |
| subset 4 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 |
| subset 5 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 |
| subset 6 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 |
| subset 7 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 |
| subset 8 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 |
| subset 9 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 |
| subset 10 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 |

| | |
|--|----------------|
| | = Data testing |
| | = Data train |

Penilaian terhadap kualitas klasifikasi dapat dilakukan dengan menghitung nilai *Area Under the Curve* – UAC, dimana sebuah algoritma memberikan klasifikasi yang baik jika mampu memperoleh nilai UAC 0,8 – 1,0 (Dewi, 2016). Dengan melakukan perbandingan nilai UAC untuk berbagai metode klasifikasi statistika, penelitian ini menyajikan data dimana nilai UAC untuk semua algoritma klasifikasi secara rata-rata memberikan nilai

UAC 5,31% lebih tinggi dibandingkan dengan nilai akurasi. Dengan kata lain, jika menggunakan nilai akurasi sebagai parameter kualitas, maka klasifikasi dengan nilai akurasi 75,97% adalah setara dengan batasan klasifikasi kategori baik (UAC 0,8).

2.7 Pemodelan Topik

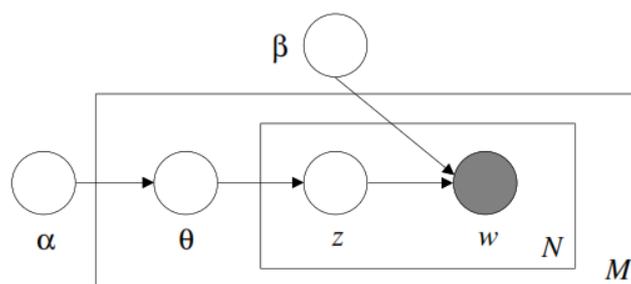
Pemodelan topik atau peringkasan teks adalah proses pengolahan data teks baik terstruktur maupun tidak terstruktur untuk mendapatkan pokok bahasan atau topik-topik yang terkandung di dalamnya. Pemodelan topik merupakan analisis teks berbasis statistik yang memiliki kemiripan dengan analisis sentimen dari sisi metode yang dipergunakan sehingga memungkinkan untuk diintegrasikan seperti yang terdapat pada penelitian Bhargava dan Sharma (2017).

Menurut El-Kassas, Salama, Rafea, dan Mohamed (2021), *text summarization* dengan pendekatan ekstraktif memiliki keuntungan dari sisi kecepatan proses dan akurasi dibandingkan dengan pendekatan *abstractive*. Hal ini dikarenakan proses *summarization* mengambil langsung dari kata/kalimat aslinya sebagai *output*, sedangkan pendekatan *abstractive* mengambil kata/kalimat asli hanya sebagai input, kemudian merangkum dan menyajikannya dengan kata/kalimat yang memiliki makna serupa (*re-phrase*). Oleh karena itu, pendekatan *extractive* cocok dipergunakan pada peringkasan teks untuk *analisis sentimen* dengan tujuan agar tidak menghilangkan poin penting dari sentimen/opini yang disampaikan. Sedangkan pendekatan *abstractive* lebih cocok untuk perangkuman naskah.

2.7.1 *Latent Dirichlet Allocation*

Latent Dirichlet Allocation (LDA) adalah salah satu pemodelan topik dengan pendekatan ekstraktif yang paling populer dan telah dipergunakan secara luas karena memiliki kelebihan dibandingkan dengan metode pemodelan topik yang lain seperti *Latent Semantic Analysis* (LSA) dan *Probabilistic Latent Semantic Analysis* (PLSA), terutama dalam hal generalisasi parameter model dan ekstraksi teks yang dihasilkan. LDA memberikan hasil ekstraksi teks dalam kelas-kelas yang memiliki karakteristik yang mirip/sama sehingga peneliti dapat menemukan pola tersembunyi (topik) dari kelas-kelas tersebut. LDA memiliki dasar pemikiran bahwa setiap dokumen memiliki topik-topik tersembunyi yang ter-karakterisasi dari sekumpulan kata tertentu (Blei, Ng, & Jordan, 2003).

Metode LDA terdiri dari tiga level data seperti ditunjukkan pada Gambar 2.2, dimana parameter pengambilan data α dan β merupakan level *corpus* yang ambil menggunakan metode probabilitas bayes, θ terdistribusi dirichlet dalam level kalimat berjumlah M kalimat, z dan w merupakan level kata yang memiliki distribusi *multinomial* sesuai jumlah topik yang ingin dibentuk. Parameter α menunjukkan kepadatan topik dalam dokumen, sehingga semakin besar nilainya, semakin banyak topik yang akan terbentuk. Parameter β menunjukkan kepadatan kata dalam topik, sehingga semakin besar nilainya, semakin banyak kata yang merepresentasikan topik yang terbentuk. Penentuan nilai proporsi parameter sampling α dan β dalam LDA sering kali bermasalah berkaitan dengan dimensi data, sehingga butuh banyak uji coba untuk mendapatkan hasil terbaik dengan menentukan nilai α dan β secara arbitrer. Semakin tinggi dimensi data, semakin tinggi tingkat kesulitan penentuan nilai optimal parameter α dan β .



Gambar 2.2. Representasi model LDA

Sumber: Blei, Ng, & Jordan (2003)

Contoh pemodelan topik menggunakan metode LDA dapat dijumpai pada penelitian Annisa, Surjandari, & Zulkarnain (2019). Penelitian ini memberikan 8 topik dari 1187 data *review* hotel di Mandalika berdasarkan nilai *coherence* tertinggi, yaitu topik ‘*Satisfaction with room*’, ‘*Fasility*’, ‘*Breakfast*’, ‘*Hotel location toward the beach*’, ‘*Tourist experience around hotel*’, ‘*Atmosphere*’, ‘*Hospitality*’, dan ‘*Bathroom*’

2.7.2 LDA-Mallet

Metode LDA-Mallet atau LDA-*Machine Learning for Language Toolkit* merupakan versi optimalisasi dari metode LDA standar yang ditulis oleh McCallum (2002). Perbedaan mendasar pada LDA-Mallet dan LDA standar adalah penggunaan tekniknya, dimana metode LDA standar menggunakan teknik sampling varian dari metode

probabilitas bersyarat Bayesian sedangkan pada LDA-Mallet menggunakan teknik sampling varian dari algoritma Markov Chain Monte Carlo – MCMC.

LDA-Mallet sedikit lebih lambat dalam proses komputasi tetapi mampu memberikan hasil pembentukan topik yang lebih presisi seperti yang dibuktikan melalui penelitian yang dikerjakan oleh Boussaadi, Aliane, & Abdeldjalil (2020). Metode MCMC lebih sesuai untuk klasifikasi data *unsupervised* seperti halnya LDA, yaitu terkait parameter inferensi sampling α dan β . Metode MCMC memiliki keunggulan dalam penentuan proporsi parameter sampling dan kemampuan komputasi data berdimensi tinggi dengan probabilitas distribusi yang rumit, dimana metode MCMC menentukan nilai optimal parameter sampling berdasarkan probabilitas distribusi data yang digunakan (Rocca, 2019).

2.8 Penelitian Terkait

Jumlah penelitian dalam lingkup analisis sentimen maupun pemodelan topik terus meningkat seiring berkembangnya keilmuan di bidang *Data Mining*, *Natural Language Processing*, dan *Machine Learning*. Analisis sentimen dan teks analisis lainnya menjadi salah satu bidang keilmuan yang penting dan terus berkembang karena sumber data yang terus meningkat seiring meningkatnya penggunaan internet dan media sosial.

Penelitian yang menggunakan analisis sentimen diintegrasikan dengan pemodelan topik telah dilakukan oleh beberapa peneliti terdahulu antara lain Calheiros, Moro, & Rita, (2017), Jeong, Yoon, & Lee (2017), Luiz, et al. (2018), dan Biraj Dahal, Sathish A. P. Kumar, & Zhenlong Li (2019) menggunakan pendekatan leksikon untuk proses ekstraksi fitur yang dilanjutkan dengan penggunaan metode klasifikasi *rule based* pada tahap analisis sentimen. Sedangkan pada pemodelan topik para peneliti ini mempergunakan metode LDA standar.

Penelitian Ali, et al. (2019) juga menggunakan integrasi analisis sentimen dan pemodelan topik, hanya saja pada penelitian tersebut menggunakan pendekatan leksikon pada ekstraksi fitur yang dilanjutkan dengan klasifikasi secara statistik. Beberapa klasifikasi statistik dipergunakan dalam penelitian ini untuk mendapatkan model yang sesuai, antara lain KNN, NB, SVM, hingga *Deep Learning*. Penelitian ini memberikan hasil metode SVM memiliki skor akurasi paling tinggi. Pada tahap pemodelan topik, penelitian ini juga memperkenalkan metode LDA topik2vec yaitu penggabungan metode LDA dengan

klasifikasi TF-IDF-SVM untuk memperbaiki hasil dengan memberikan kata yang memiliki kemiripan sebagai *output*-nya. Belum ada studi lanjutan dan hasil evaluasi pengujian terkait metode ini.

Meskipun menggunakan pendekatan metode klasifikasi sentimen yang berbeda, penelitian sentimen analisis jendela waktu seperti yang telah dilakukan beberapa peneliti sebelumnya seperti yang dikerjakan oleh Wang, Wu, Zhang, & Zhu (2020), Rao & Srivastava (2012), dan Yoo, Song, & Jeong (2018) memberikan gambaran bahwa sentimen analisis jendela waktu mampu dipergunakan secara efektif untuk kebutuhan identifikasi, deteksi, hingga prediksi terkait suatu kejadian dengan melakukan analisis tren polaritas sentimen.

Ringkasan penelitian yang terkait dengan penelitian ini dapat dilihat pada Tabel 2.3 dan Tabel 2.4.

2.9 Usulan Penelitian

Berdasarkan pustaka yang telah diuraikan di atas, penelitian pada tahapan sentimen akan menggunakan pendekatan *lexicon-rule based classification* dan evaluasi manual pada tahap klasifikasi data latih agar diperoleh klasifikasi yang konsisten dan sesuai dengan konteks penelitian. Selanjutnya dari data latih yang telah diperoleh polaritas sentimennya tersebut dilakukan pembuatan model klasifikasi TF-IDF-SVM. Pengujian dan evaluasi dilakukan pada tahap pembuatan model ini. Selanjutnya adalah klasifikasi keseluruhan data menggunakan model yang telah dibuat. Data yang telah terklasifikasi selanjutnya digunakan dalam penelitian sesuai tujuan dari penelitian ini, yaitu menghitung korelasi sentimen yang sebelum dan selama masa pandemi sejak peraturan pemerintah dan keputusan presiden tentang penanganan pandemi ditetapkan. Selain itu, pemodelan topik dengan metode LDA-Mallet juga dilakukan terhadap data ini, dimana ekstraksi topik akan terbagi dalam topik-topik sentimen sebelum dan topik-topik sentimen yang ada selama pandemi. Jumlah topik optimal akan ditentukan dengan metode *elbow* sesuai dengan nilai signifikan *coherence* tertinggi yang dapat dicapai.

Berdasarkan konteks penelitian, belum dijumpai penelitian yang memiliki tujuan penelitian sejenis mengkorelasikan pandemi covid-19 dengan sentimen layanan jasa pengiriman barang dan pemodelan topik, khususnya untuk studi kasus di Indonesia. Metode dalam sentimen analisis dan pemodelan topik mempunyai sangat banyak varian

dan kombinasi, sehingga dari sisi metode yang digunakan, belum dijumpai penggunaan metode yang sama pada penelitian sejenis.

Tabel 2.3 Ringkasan penelitian terkait

| No. | Author | Year | Title | Sources | | | | | Sentiment Analysis | | | | | | | | Topic Modeling | |
|-----|--|------|--|----------|-----------|---------|---------|-------|--------------------|-------------|-------------|-------------|------------|-----|-----|-----|----------------|-----|
| | | | | | | | | | Type | | Term weight | | Classifier | | | | | |
| | | | | Facebook | Traveloka | TripAdv | Twitter | Other | Single | Time Window | Lexical | Statistical | Rule Based | KNN | NBC | SVM | DL | LDA |
| 1 | Zulkarnain; Isti Surjandari; Regia Aldiana Wayasti | 2018 | Sentiment analysis for mining customer opinion on twitter: a case study of ride-hailing service provider | | | | X | | | | | X | | | | | X | |
| 2 | Annisa Marlin Masbar Rus; Rossi Annisa; Isti Surjandari; Zulkarnain | 2019 | Measuring Hotel Service Quality in Borobudur Temple Using Opinion Mining | | X | | | | | | X | X | | X | X | | X | |
| 3 | Rossi Annisa; Isti Surjandari; Zulkarnain | 2019 | Opinion Mining on Mandalika Hotel Reviews Using Latent Dirichlet Allocation | | X | | | | | | | | | | | | X | |
| 4 | Boussaadi, Smail; Aliane, Hassina; Abdeldjalil, Ouahabi | 2020 | The Researchers Profile with Topic Modeling | | | | | X | | | | | | | | | X | X |
| 5 | Ana Catarina Calheiros; Sérgio Moro; Paulo Rita | 2017 | Sentiment Classification of Consumer-Generated Online Reviews Using Topic Modeling | | | X | | X | X | | X | | X | | | | X | |
| 6 | Byeongki Jeong; Janghyeok Yoon; Jae-Min Lee | 2017 | Social media mining for product planning: A product opportunity mining approach based on topic modeling and sentiment analysis | | | | | X | X | | X | | X | | | | X | |
| 7 | Washington Luiz; Felipe Viegas; Rafael Alencar; Fernando Mourao; Thiago | 2018 | A Feature-Oriented Sentiment Rating for Mobile App Reviews | | | | | X | X | | X | | X | | | | X | |
| 8 | Farman Ali; Daehan Kwak; Pervez Khan; Shaker El-Sappagh; Amjad Ali; Sana Ullah; Kye Hyun Kim; Kyung-Sup Kwak | 2019 | Transportation sentiment analysis using word embedding and ontology-based topic modeling | X | | X | X | X | X | | X | | | X | X | X | X | |
| 9 | Biraj Dahal; Sathish A. P. Kumar; Zhenlong Li | 2019 | Topic modeling and sentiment analysis of global climate change tweets | | | | X | | X | | X | | X | | | | X | |

KNN - K Nearest Neighbor, NBC - Naive Bayes Classifier, SVM - Support Vector Machine, DL - Deep Learning, LDA - Latent Dirichlet Allocation

Tabel 2.4 Ringkasan penelitian terkait (lanjutan)

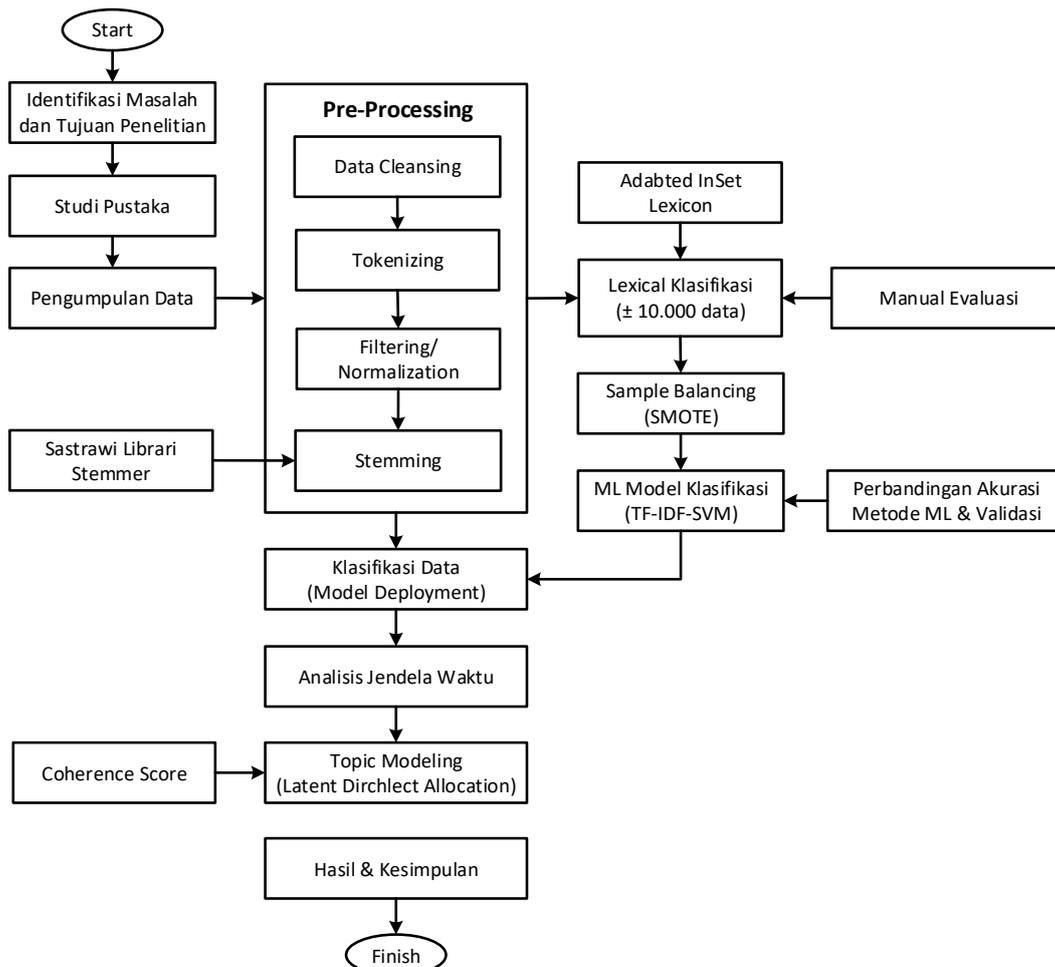
| No. | Author | Year | Title | Sources | | | | | Sentiment Analysis | | | | | | | | | Topic Modeling | |
|-----|---|------|--|----------|-----------|---------|---------|-------|--------------------|-------------|-------------|-------------|------------|-----|-----|-----|----|----------------|------------|
| | | | | | | | | | Type | | Term weight | | Classifier | | | | | | |
| | | | | Facebook | Traveloka | TripAdv | Twitter | Other | Single | Time Window | Lexical | Statistical | Rule Based | KNN | NBC | SVM | DL | LDA | LDA-Mallet |
| 10 | Mingyang Wang; Huan Wu; Tianyu Zhang; Shengqing Zhu | 2020 | Identifying critical outbreak time window of controversial events based on sentiment | | | | | X | | X | X | | | X | | | | | |
| 11 | Tushar Rao; Saket Srivastava | 2012 | Analyzing stock market movements using Twitter sentiment analysis | | | | X | | | X | X | | | | X | | | | |
| 12 | SoYeop Yoo; JeIn Song; OkRan Jeong | 2018 | Social media contents based sentiment analysis and prediction system | | | | X | | | X | X | X | | | | | X | | |
| 13 | Usulan Penelitian | 2021 | Analisis Sentimen dan Topic Modeling Pada Layanan Pengiriman Barang Sebelum dan Selama Pandemi | | | | X | | | X | X | X | X | | | X | | | X |

KNN - K Nearest Neighbor, NBC - Naive Bayes Classifier, SVM - Support Vector Machine, DL - Deep Learning, LDA - Latent Dirichlet Allocation

BAB 3 METODE PENELITIAN

3.1 Rancangan penelitian

Adapun rancangan penelitian ini dilakukan seperti yang ditunjukkan pada Gambar 3.1 di bawah ini.



Gambar 3.1 Diagram alir tahapan penelitian

Berdasarkan Gambar 3.1, penelitian dimulai dengan mengidentifikasi masalah dan tujuan penelitian. Studi pustaka / *literature review* diperlukan untuk menentukan teknik dan metode yang sesuai guna menjawab pertanyaan penelitian. Keseluruhan proses penelitian akan menggunakan *software* Python 3.8 Jupyter Notebook serta pustaka Python yang umum dipergunakan dalam data analisis seperti Pandas dan Numpy, pustaka Twint dalam proses pengumpulan data, pustaka NLTK dan Sastrawi dalam *preprocessing*, pustaka Sklearn dalam proses klasifikasi statistik, pustaka Gensim dan Mallet dalam pemodelan

topik, serta pustaka-pustaka Python lain yang merupakan dependensi dari pustaka-pustaka yang telah disebutkan.

3.1.1 Pengumpulan Data

Pengumpulan data pada penelitian ini menggunakan teknik web *scraping* dengan menggunakan pustaka Python Twint. Twint atau disebut juga dengan *Twitter Intelligence Tool* merupakan pustaka Python yang ditulis oleh Zacharias (2020). Twint memiliki beberapa keunggulan bila dibandingkan dengan *tweet* mining lain yaitu: dapat mengambil hampir seluruh data *tweet* (bandingkan Twitter API dengan maksimum 3200 *tweet*), pengaturan dan bahasa program yang sederhana, tidak membutuhkan akun, dan bebas dari batasan-batasan yang dibuat oleh Twitter. Kode program Python menggunakan pustaka Twint untuk proses pengumpulan data dapat dilihat pada Gambar 3.2.

```
import twint
import nest_asyncio
nest_asyncio.apply()

# Configure
c = twint.Config()
c.Search = "keyword"
c.Since = "start date"
c.Until = "end date"
c.Store_csv = True
c.Output = "file path/file.csv"
twint.run.Search(c)
```

Gambar 3.2. Kode Python *tweet scraping* menggunakan pustaka Twint

Untuk mengurangi potensi kesalahan selama pengambilan data, maka proses *scraping* dilakukan dengan cara bertahap, yaitu tiap penyedia layanan tiap bulan. Hasil pengumpulan data ini kemudian digabungkan pada tahap akhir proses. Kode program Python untuk proses penggabungan seluruh data dapat dilihat pada Gambar 3.3.

```
import os
import glob
import pandas as pd
os.chdir("file directory path")
extension = 'csv'
all_filenames = [i for i in glob.glob('*.{}'.format(extension))]
combined_csv = pd.concat([pd.read_csv(f) for f in all_filenames ])
combined_csv.to_csv( "combined_file.csv", index=False, encoding='utf-8-sig')
```

Gambar 3.3. Kode program Python untuk penggabungan seluruh data

Data diambil dari media sosial Twitter dengan rentang waktu awal Oktober 2019 hingga akhir September 2020 dengan kata kunci sesuai akun-akun resmi yang dipergunakan penyedia layanan sebagai pusat pengaduan dan layanan pelanggan, yaitu @JNE_ID dan @JNECare untuk JNE, @jntexpressid untuk J&T, @PosIndonesia untuk Pos Indonesia, @TIKICare dan @IdTiki untuk TIKI, dan @sicepat_ekspres untuk SiCepat.

3.1.2 Data Preprocessing

```
#remove sentence which contains only one word
def removeSentence(str):
    word = str.split()
    wordCount = len(word)
    if(wordCount<=1):
        str = ''

    return str

def cleaning(str):
    #to lowercase
    str = str.lower()
    # remove tab, new line, ans back slice
    str = str.replace('\t',' ').replace('\n',' ').replace('\u',' ').replace('\',"'")
    #remove non-ascii
    str = unicodedata.normalize('NFKD', str).encode('ascii', 'ignore').decode('utf-8', 'ignore')
    # remove mention, link, hashtag
    str = ' '.join(re.sub("([@#][^\s+])|(\w+:\w+\/\w+\/\w+)", " ", str).split())
    #remove URLs
    str = re.sub(r'(?i)\b(?:https?://|www\d{0,3}[.]|[a-z0-9.-]+[.][a-z]{2,4}/)(?:[^\s()<>]|\\((
    #remove punctuations
    str = re.sub(r'[^a-zA-Z]|_', ' ', str)
    #remove digit from string
    str = re.sub("\S*\d\S*", "", str).strip()
    #remove digit or numbers
    str = re.sub(r"\b\d+\b", " ", str)
    #function to help with exxagerated words
    str = re.sub(r'([\w])\1+', r'\1', str)
    # remove 1 char words
    str = re.sub(r"\b[a-zA-Z]\b", "", str)
    #Remove additional white spaces
    str = re.sub('[\s]+', ' ', str)
    #remove whitespace leading & trailing
    str = str.strip()
    return str

def preprocessing(str):
    str = removeSentence(str)
    str = cleaning(str)
    return str

df['clean_tweet'] = df['tweet'].apply(preprocessing)

# NLTK word tokenize
def word_tokenize_wrapper(text):
    return word_tokenize(text)

df['tokenized_tweet'] = df['clean_tweet'].apply(word_tokenize_wrapper)
```

Gambar 3.4. Proses *normalize case*, data *cleansing* dan *tokenization*

Data yang dikumpulkan dari media sosial Twitter merupakan data yang tidak terstruktur sehingga membutuhkan *preprocessing*. Proses ini merupakan tahapan yang sangat

penting dalam analisis sentimen maupun analisis teks yang lain karena akan mempengaruhi keseluruhan hasil analisis. Seperti yang dijelaskan pada bab sebelumnya, tahapan *data preprocessing* terdiri dari *normalize case*, *data cleansing*, *tokenization*, *normalize spelling*, *stopword removal*, dan *stemming*. Gambar 3.4 memperlihatkan kode program untuk proses *normalize case*, *data cleansing*, dan *tokenization*.

```
#----- Normalizing -----
normalized_word = pd.read_excel("D:/@Magister/UI/Therm_4/Thesis/@Analysis/data/00_dictionary/normalisasi.xlsx")
normalized_word_dict = {}

for index, row in normalized_word.iterrows():
    if row[0] not in normalized_word_dict:
        normalized_word_dict[row[0]] = row[1]

def normalized_term(document):
    return [normalized_word_dict[term] if term in normalized_word_dict else term for term in document]

df['norm_token_tweet'] = df['tokenized_tweet'].apply(normalized_term)
```

Gambar 3.5. Proses *normalize spelling*

Gambar 3.5 memperlihatkan kode program yang dipergunakan dalam proses normalisasi. Proses ini membutuhkan berkas masukan berupa daftar kata tidak baku. Untuk diketahui, proses pembuatan daftar ini membutuhkan waktu yang cukup panjang, mengingat seluruh kata yang berhasil dimasukkan ke dalam daftar diperoleh secara manual. Contoh beberapa kata tidak baku tersebut dapat dilihat pada Tabel 3.1.

Tabel 3.1. Contoh daftar kata tidak baku

| Slang | Formal | Slang | Formal |
|---------|----------|--------|---------|
| abiz | habis | bner | benar |
| adlah | adalah | brubah | berubah |
| aktip | aktif | esmosi | emosi |
| barng | barang | gedeg | jengkel |
| begerak | bergerak | gile | gila |

Proses *stopword removal* juga memerlukan berkas masukan yang berisi daftar kata-kata yang masuk dalam kelompok *stopword* seperti yang dapat dilihat pada kode program Gambar 3.6. Daftar kata-kata yang masuk dalam kelompok *stopword* dalam bahasa Indonesia telah tersedia dalam pustaka Python, NLTK *stopword 'indonesian'*. Penelitian ini mengadopsi daftar yang telah disediakan tersebut dengan melakukan beberapa penyesuaian dengan mengurangi beberapa kata yang sesuai untuk dijadikan fitur atau menambahkan beberapa kata yang belum ada disesuaikan dengan konteks penelitian.

Tabel 3.2. Contoh kata *stopword*

| | | | | |
|--------|----------|---------|----------|--------------|
| atas | kah | lagi | minggu | terlebih |
| aku | kala | lah | minta | terlihat |
| & | kalau | lain | misal | termasuk |
| acara | kalaulah | lainnya | misalnya | ternyata |
| adalah | kalaupun | lalu | mulai | tersampaikan |

Contoh daftar kata-kata yang masuk dalam kelompok *stopword* berbahasa Indonesia dapat dilihat pada Tabel 3.2.

```
# get stopwords indonesia
txt_stopword = open("D:/@Magister/UI/Therm_4/Thesis/@Analysis/data/00_dictionary/combined_stop_words.txt", "r")
content = txt_stopword.read()
list_stopwords = content.split("\n")
txt_stopword.close()

# ----- manually add stopwords -----
# append additional stopwords
list_stopwords.extend(["yg", "dg", "rt", "dgn", "ny", "d", 'klo',
                      'kalo', 'amp', 'iya', 'admin', 'resi', 'sicepat',
                      'no', 'sat', 'nomor', 'jp', 'jampt', 'eh', 'kah',
                      'mah', 'an', 'he', 'pt', 'nya', 'al', 'fb', 'nya', 'jnt'])

# convert list to dictionary
list_stopwords = set(list_stopwords)

# remove stopwords pada list token
def stopwords_removal(words):
    return [word for word in words if word not in list_stopwords]

df['norm_token_WSW_tweet'] = df['norm_token_tweet_2'].apply(stopwords_removal)
```

Gambar 3.6. Kode proses *stopword removal*

Selanjutnya adalah proses *stemming*, dimana dalam penelitian ini proses *stemming* atau pembentukan kata dasar menggunakan bantuan pustaka Python Sastrawi. Kode program untuk proses *stemming* dengan pustaka Sastrawi dapat dilihat pada Lampiran 1.

3.1.3 Klasifikasi Data Latih

Tahap klasifikasi data latih dimulai dengan melakukan sampling pada data ‘bersih’ yang telah melalui tahap *preprocessing*. Teknik *stratified random sampling* dipergunakan dalam proses pengambilan sampel, dimana sampel diambil secara acak berdasarkan persentase yang sama tiap penyedia layanan tiap bulannya. Data yang dijadikan sampel dalam tahap ini berjumlah $\pm 10,000$ data.

Dengan menggunakan sumber leksikon dari Koto & Rahmaningtyas (2017) yang telah di modifikasi, seluruh data sampel diklasifikasikan dalam polaritas ‘Positif’, ‘Netral’, atau ‘Negatif’ dengan pendekatan klasifikasi *rule based*. Hasil klasifikasi selanjutnya dievaluasi secara manual untuk memastikan proses klasifikasi telah dilakukan dengan benar dan sesuai dengan interpretasi peneliti.

Formulasi perhitungan skor sentimen untuk setiap kalimat dalam data sampel adalah sebagai berikut:

$$Sentence_score = \sum_{i=1}^n \begin{cases} \text{if } (term_{i-1} = \text{negasi}), \text{ then } - (w_i + 1) \\ w_i \end{cases} \quad (3.1)$$

Dimana:

w = bobot sentimen kata berdasarkan sumber leksikon

Penambahan bobot 1 poin pada kata bernegasi dikarenakan beberapa kalimat dalam *tweet* memiliki bentuk negasi disertai kata berulang. Contoh kalimat ‘barang tidak sampai sampai’, kalimat tersebut secara harfiah memiliki polaritas negatif. Kata ‘barang’ tidak terdapat pada sumber leksikon sehingga memiliki bobot sentimen 0, sedangkan kata ‘sampai’ memiliki bobot sentimen +1, sehingga apabila tidak ditambahkan dengan 1 poin, maka skor kalimat tersebut akan memiliki skor $0-1+1 = 0$ (netral), dengan penambahan poin pada kata bernegasi skor sentimen untuk kalimat tersebut menjadi $0-(1+1)+1 = -1$ (negatif). Kode ekstraksi fitur secara lengkap dapat dilihat pada Lampiran 2.

Rule yang digunakan dalam menentukan kelas dari data latih menerapkan aturan seperti yang disebutkan pada bab sebelumnya, sehingga dalam format kode program dapat dilihat pada Gambar 3.7.

```
def getAnalysis(score):
    if score < 0:
        return 'Negative'
    elif score == 0:
        return 'Neutral'
    else:
        return 'Positive'

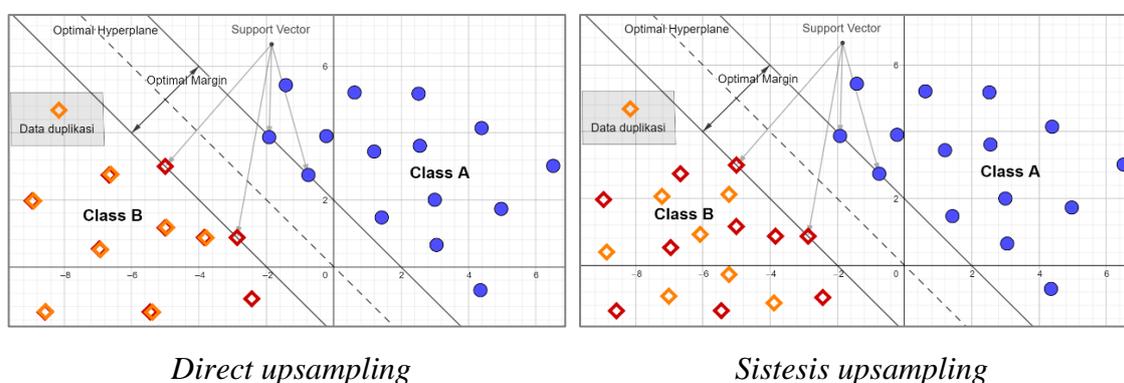
cek_df['sentiment'] = cek_df['score'].apply(getAnalysis)
```

Gambar 3.7. Kode aturan klasifikasi data latih.

Data latih yang telah terklasifikasi kemungkinan besar akan memiliki jumlah polaritas yang berbeda sehingga perlu dilakukan penyeimbangan data. Penyeimbangan data merupakan langkah penting dalam klasifikasi data dengan pendekatan statistik untuk mengurangi atau menghindari terjadinya *overfitting* maupun *underfitting*. *Overfitting* adalah kondisi dimana model hanya memiliki varian data latih yang kecil meskipun secara jumlah memiliki sampel yang besar, sehingga model memiliki nilai akurasi yang tinggi. Sedangkan *underfitting* adalah kondisi dimana model tidak memiliki jumlah data

yang mencukupi terhadap besarnya varian data latih. Baik *overfitting* maupun *underfitting* akan menyebabkan kualitas generalisasi model yang rendah apabila diaplikasikan untuk mengklasifikasi data baru.

Dalam penelitian ini, proses penyeimbangan data latih akan menggunakan metode *upsampling* SMOTE (*System Minority Oversampling Technique*). Metode SMOTE berbeda dengan metode penyeimbang data secara umum, dimana metode ini tidak membuat duplikasi secara langsung dari data minoritas tetapi menyintesis data baru menggunakan pendekatan KNN berdasarkan karakter data minoritas (Chawla, Bowyer, Hall, & Kegelmeyer, 2002). Gambar 3.8 menyajikan ilustrasi perbandingan duplikasi data secara langsung dan duplikasi sintesis.



Gambar 3.8. Ilustrasi *direct upsampling* vs. *sintesis upsampling*

3.1.4 Klasifikasi Keseluruhan Data

Tahap klasifikasi data dalam penelitian ini menggunakan pendekatan statistik baik dalam proses ekstraksi fitur maupun proses klasifikasinya. Pendekatan ekstraksi fitur yang dipergunakan adalah metode TF-IDF, sedangkan proses klasifikasi akan menggunakan metode SVM. Pengujian dan evaluasi seperti pengukuran akurasi, presisi, *recall*, *f1-score* dan *10-fold cross validation* dilakukan pada model yang telah dibuat ini. Model selanjutnya dipergunakan untuk mengklasifikasi keseluruhan data.

Perhitungan nilai akurasi, presisi, *recall*, maupun *f1-score* menggunakan *confusion matrix* seperti yang ditunjukkan pada Tabel 2.1 pada bab sebelumnya. Sedikit berbeda pada jumlah kelas polaritas sentimen yang digunakan, klasifikasi kelas sentimen dalam penelitian ini menggunakan tiga klasifikasi polaritas yaitu: ‘Positif’, ‘Netral’, dan ‘Negatif’, maka pembentukan *confusion matrix* akan terdiri dari tiga elemen seperti dapat dilihat pada Tabel 3.3.

Tabel 3.3. *Confussion matrix* tiga elemen

| | | Kelas Prediksi | | |
|------------------|----------|---------------------------|---------------------------|---------------------------|
| | | Positive | Neutral | Negative |
| Kelas Sebenarnya | Positive | TP (True Positive) | FP1 (False Positive 1) | FP2 (False Positive 2) |
| | Neutral | FNn1 (False Neutral 1) | TNn (True Neutral) | FNn2 (False Neutral 2) |
| | Negative | FN1 (False Negative 1) | FN2 (False Negative 2) | TN (True Negative) |

Dalam *confussion matrix* ini terdapat sembilan (9) status yang mewakili kemungkinan hasil prediksi klasifikasi, yaitu:

1. *TP / True Positive*, data sebenarnya ‘Positif’ dan hasil prediksi ‘Positif’.
2. *FP1 / False Positive 1*, data sebenarnya ‘Positif’ dan hasil prediksi ‘Netral’.
3. *FP2 / False Positive 2*, data sebenarnya ‘Positif’ dan hasil prediksi ‘Negatif’.
4. *TNn / True Neutral*, data sebenarnya ‘Netral’ dan hasil prediksi ‘Netral’.
5. *FNn1 / False Neutral 1*, data sebenarnya ‘Netral’ dan hasil prediksi ‘Positif’.
6. *FNn2 / False Neutral 2*, data sebenarnya ‘Netral’ dan hasil prediksi ‘Negatif’.
7. *TN / True Negative*, data sebenarnya ‘Negatif’ dan hasil prediksi ‘Negatif’.
8. *FN1 / False Negative 1*, data sebenarnya ‘Negatif’ dan hasil prediksi ‘Positif’.
9. *FN2 / False Negative 2*, data sebenarnya ‘Negatif’ dan hasil prediksi ‘Netral’.

Perhitungan nilai akurasi dapat dilihat pada Persamaan 3.2 berikut:

$$Accuracy = \frac{TP+TNn+TN}{Overall\ Data} \quad (3.2)$$

Perhitungan nilai presisi untuk kelas ‘Positif’, ‘Netral’, dan ‘Negatif’ dapat dilihat pada Persamaan 3.3, Persamaan 3.4, dan Persamaan 3.5 berikut:

$$Precision\ for\ Positive\ Prediction = \frac{TP}{TP+FNn1+FN1} \quad (3.3)$$

$$Precision\ for\ Neutral\ Prediction = \frac{TNn}{FP1+TNn+FN2} \quad (3.4)$$

$$Precision\ for\ Negative\ Prediction = \frac{TN}{FP2+FNn2+TN} \quad (3.5)$$

Perhitungan nilai *recall* untuk kelas ‘Positif’, ‘Netral’, dan ‘Negatif’ dapat dilihat pada Persamaan 3.6, Persamaan 3.7, dan Persamaan 3.8 berikut:

$$Recall\ for\ Positive\ Prediction = \frac{TP}{TP+FP1+FP2} \quad (3.6)$$

$$\text{Recall for Neutal Prediction} = \frac{TNn}{FNn1+TNn+FNn2} \quad (3.7)$$

$$\text{Recall for Negative Prediction} = \frac{TN}{FN1+FN2+TN} \quad (3.8)$$

Adapun untuk perhitungan nilai *f1-score* secara umum dapat dilihat pada menggunakan persamaan yang sama seperti disebutkan pada bab sebelumnya.

Adapun sebagai pembanding, dalam penelitian ini akan dipergunakan beberapa metode klasifikasi statistika populer yang lain yaitu metode *KNearest Neighbors (KNN)*, *Naive Bayes Classifier (NB)*, dan *Random Forest (RF)*. Perbandingan hasil klasifikasi ini diperlukan untuk mengetahui apakah metode SVM dapat dipergunakan dan merupakan pilihan paling sesuai untuk mengklasifikasi data yang dimiliki.

Proses klasifikasi dengan menggunakan metode SVM dan beberapa metode klasifikasi statistika pembanding hingga proses evaluasi model memanfaatkan pustaka Python Sklearn, dimana pustaka ini telah memiliki metode klasifikasi, pengujian dan evaluasi secara lengkap, salah satunya metode TF-IDF-SVM serta metode evaluasi *k-fold cross validation*.

3.1.5 Analisis Jendela Waktu

Setelah tahap teknis analisis sentimen dilakukan, tahap selanjutnya adalah melakukan analisis sesuai dengan tujuan penelitian yaitu untuk mengetahui korelasi antara pandemi dengan tren sentimen yang terjadi pada layanan pengiriman barang. Dalam analisis korelasi ini, penetapan Peraturan Pemerintah dan Keputusan Presiden tentang penanganan pandemi dijadikan patokan dimulainya masa pandemi.

Uji korelasi dan signifikansi hubungan antara pandemi dan tren sentimen akan menggunakan metode korelasi *Spearman*, dimana uji korelasi ini sesuai untuk data non-parametrik dan tidak memerlukan pengujian distribusi data. Analisis tambahan seperti tren jumlah *tweet* maupun analisis eksploratori data lainnya mungkin saja dilakukan dalam tahap ini.

3.1.6 Pemodelan Topik

Pemodelan topik dalam penelitian ini menggunakan pendekatan LDA-Mallet (*Latent Dirichlet Allocation - Machine Learning for Language Toolkit*) dengan menggunakan tiga *sub-set* dari keseluruhan data yang telah terklasifikasi polaritas sentimennya. Ketiga *sub-*

set data tersebut yaitu data sebelum pandemi, tiga bulan pertama masa pandemi, dan terakhir tiga bulan kedua masa pandemi. Hal ini untuk mengetahui apakah terjadi perubahan topik dalam tiga rentang waktu tersebut. Setiap *sub-set* data akan dilakukan ekstraksi topik untuk masing-masing polaritas sentimen, sehingga akan diperoleh topik-topik untuk tiap kelas sentimen untuk masing-masing *sub-set* rentang waktu.

Tahap pemodelan topik ini menggunakan pustaka Python Gensim yang diintegrasikan dengan pustaka Mallet, sedangkan penentuan jumlah topik yang diekstraksi menggunakan teknik pengukuran skor *coherence*, dimana jumlah topik akan dipilih berdasarkan skor *coherence* tertinggi. Skor *coherence* adalah pengukuran kemiripan makna dari sekumpulan kata dalam topik yang bersangkutan, semakin tinggi skor, semakin baik topik yang dibentuk.

3.1.7 Hasil dan Kesimpulan

Setelah semua tahap sebelumnya dilakukan, maka tahap ini memberikan pemaparan tentang hasil dan memberikan kesimpulan dari keseluruhan proses analisis, baik analisis sentimen maupun pemodelan topik, hingga kendala-kendala yang dihadapi.

BAB 4

HASIL DAN PEMBAHASAN

4.1 Pengumpulan Data

Tahap pengumpulan seluruh data telah selesai dilakukan sepenuhnya pada bulan Desember 2020. Pada tahap ini berhasil diperoleh 354.999 data dari pesan yang menyebutkan akun-akun resmi penyedia jasa pengiriman barang dengan rentang waktu 01 Oktober 2019 sampai dengan 30 September 2020. Data yang berhasil dikumpulkan pada tahap awal ini memiliki 37 variabel berbeda, yaitu:

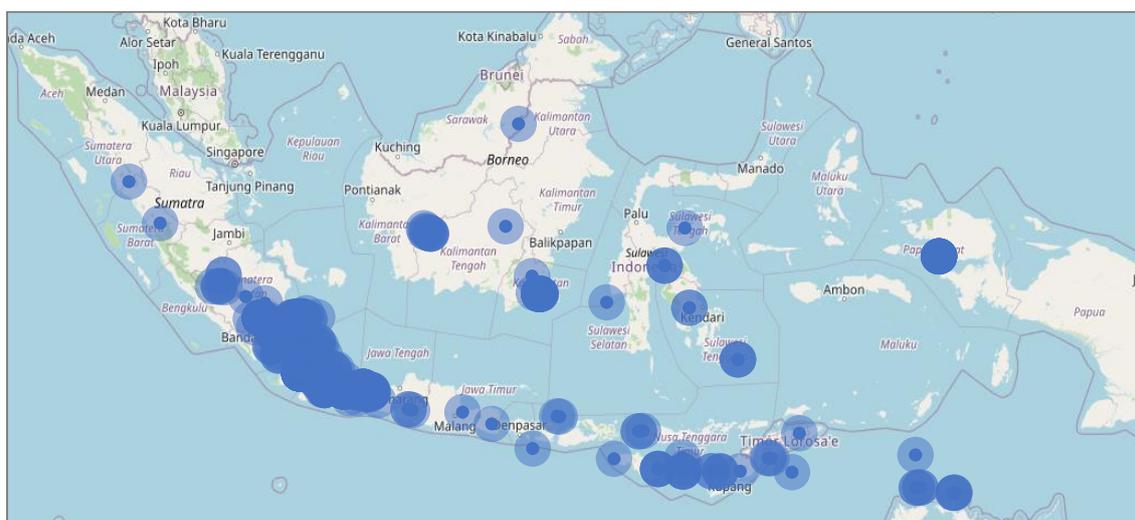
1. *Id*, memuat informasi tentang nomor indeks data
2. *Conversation_id*, memuat informasi tentang nomor urut percakapan
3. *Create_at*, memuat informasi tentang kapan percakapan dilakukan dengan format lengkap (*date, time, timezone*).
4. *Date*, memuat informasi tentang tanggal percakapan dilakukan
5. *Time*, memuat informasi tentang jam percakapan dilakukan
6. *Timezone*, memuat informasi tentang zona waktu dimana percakapan dilakukan
7. *User_id*, memuat informasi tentang nomor identitas pengguna yang memposting status.
8. *Username*, memuat informasi tentang nama yang digunakan oleh pengguna yang memposting status.
9. *Name*, memuat informasi tentang nama asli pengguna (banyak record tidak berisi data)
10. *Place*, memuat informasi koordinat dimana status tersebut dibuat (banyak record tidak berisi data)
11. *Tweet*, memuat informasi konten teks/pesan.
12. *Language*, memuat informasi pengaturan bahasa yang dipergunakan oleh pengguna yang bersangkutan.
13. *Mention*, memuat informasi ke akun mana saja pesan ditujukan dengan menyebutkan nama-nama akun tersebut.
14. *Urls*, memuat informasi bila pesan berisi tautan ke alamat web site tertentu.
15. *Photos*, memuat informasi tautan ke folder media Twitter bila pesan konten gambar/grafis.

16. *Replies_count*, memuat informasi jumlah balasan dari pesan tersebut.
17. *Retweets_count*, memuat informasi jumlah pesan tersebut diteruskan.
18. *Likes_count*, memuat informasi jumlah pesan tersebut mendapat respons.
19. *Hashtags*, memuat informasi topik pembicaraan yang dikaitkan dengan pesan yang ditulis.
20. *Cashtags*, memuat informasi finansial berkaitan dengan topik tertentu.
21. *Link*, memuat informasi tautan letak pesan di web site Twitter.
22. *Retweet*, memuat informasi *boolean* apakah pesan ini merupakan pesan yang diteruskan atau tidak.
23. *Quote_url*, memuat informasi apabila pesan disalin dari akun lain.
24. *Video*, memuat informasi tautan ke folder media Twitter bila pesan konten video/grafis.
25. *Thumbnail*, memuat *preview* sebuah pesan yang biasanya berupa pesan video, gambar, atau konten grafis lainnya.
26. *Near*, tidak memuat informasi apapun.
27. *Geo*, tidak memuat informasi apapun.
28. *Source*, tidak memuat informasi apapun.
29. *User_rt_id*, tidak memuat informasi apapun.
30. *User_rt*, tidak memuat informasi apapun.
31. *Retweet_id*, tidak memuat informasi apapun.
32. *Reply_to*, memuat informasi ke akun mana saja pesan balasan tersebut ditujukan dengan menyebutkan nama akun pembuat pesan aslinya.
33. *Retweet_date*, tidak memuat informasi apapun.
34. *Translate*, tidak memuat informasi apapun.
35. *Trans_src*, tidak memuat informasi apapun.
36. *Trans_dest*, tidak memuat informasi apapun.
37. *Origin*, merupakan variabel yang ditambahkan oleh penulis untuk membedakan asal data berdasarkan penyedia layanan.

Tidak semua variabel pada data ini dipergunakan dalam analisis, melainkan beberapa variabel yang berhubungan dengan analisis sentimen dan pemodelan topik saja. Variabel yang dipergunakan tersebut antar lain: *'id'*, *'date'*, *'origin'*, *'place'*, *'username'*, *'language'*, dan *'tweet'*. Variabel *'month'* juga ditambahkan dalam *dataframe* yang

diturunkan dari variabel *'date'*, dimana variabel ini berguna untuk memisahkan data berdasarkan bulan sesuai dengan batasan analisis.

Untuk mengetahui demografi lokasi tiap pengguna, variabel *Place* dapat dipergunakan untuk memperoleh koordinat lokasi dari mana *tweet* berasal. Sayangnya, variabel *Place* dari data yang dikumpulkan tidak memuat informasi yang cukup lengkap, yaitu hanya berisikan 109 informasi koordinat pengguna. Hal ini terjadi karena Twitter tidak mengharuskan pengguna untuk mengaktifkan fitur berbagi lokasi sebagai salah satu kebijakan privasinya.

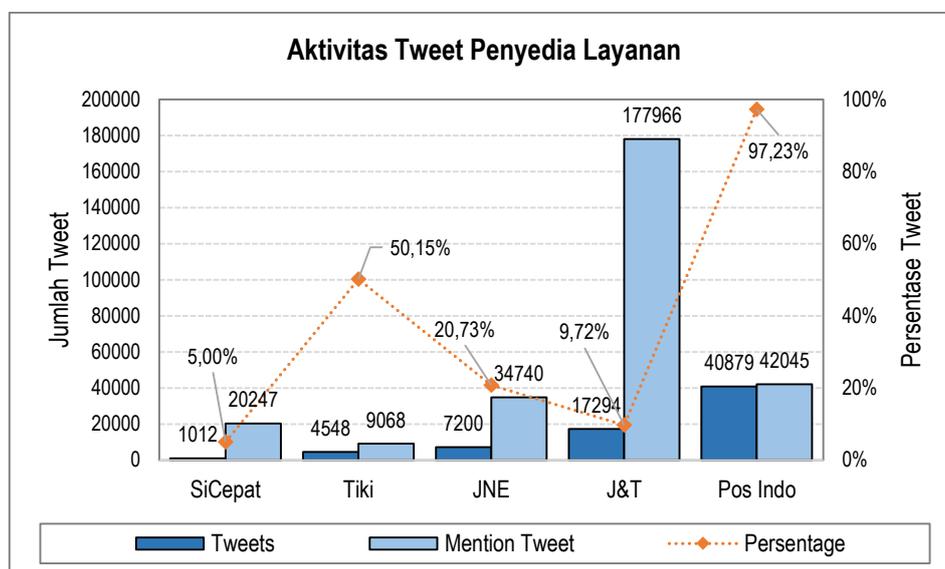


Gambar 4.1. Data sebaran lokasi pesan

Namun demikian, berdasarkan informasi yang tersedia ini dapat dilihat pada Gambar 4.1 bahwa lokasi *tweet* memiliki sebaran hampir di seluruh wilayah Indonesia bahkan beberapa pesan berasal dari luar negeri seperti Malaysia dan Australia, meskipun mayoritas *tweet* ini berasal dari bagian barat pulau Jawa seperti daerah DKI Jakarta, Tangerang dan Banten, Jawa Barat, sebagian Jawa Tengah dan pulau Sumatera bagian selatan seperti Lampung dan Sumatera Selatan.

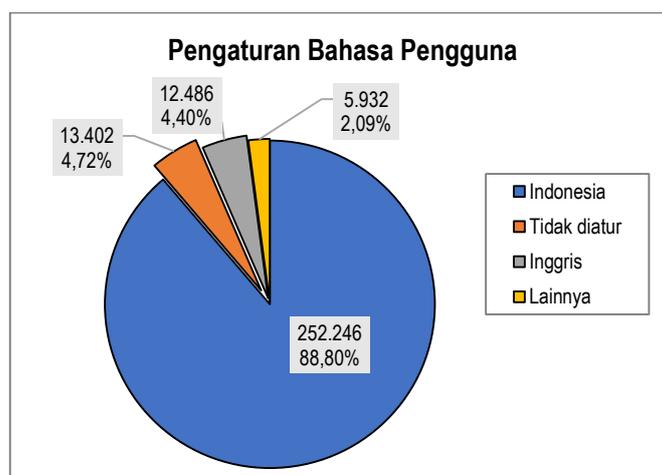
Aktivitas *tweet* dari penyedia jasa layanan menunjukkan keaktifan layanan pelanggan dalam menyampaikan informasi, konfirmasi, tanggapan atas pertanyaan, hingga tanggapan atas keluhan yang disampaikan oleh pelanggannya. Data aktivitas tweet akun resmi dapat dilihat pada Gambar 4.2, dimana gambar ini memperlihatkan bahwa Pos Indonesia merupakan penyedia jasa layanan paling aktif yaitu 97,23% atau 40.879 dibandingkan dengan 42,045 *tweet* dari akun lain yang *me-mention* akunnya. Disusul oleh

Tiki 50,15%, JNE 20,73%, J&T 9,72%, dan di urutan terakhir SiCepat dengan 5,00%. Adapun *Tweet* yang berasal dari akun resmi ini tidak ikut dipergunakan dalam analisis, sehingga data yang dipergunakan selanjutnya merupakan data *tweet* yang berasal selain dari akun resmi saja, yaitu berjumlah 284.066 data.



Gambar 4.2. Aktivitas *tweet* akun resmi penyedia layanan

Berdasarkan pengaturan bahasa yang digunakan, data yang *mention* akun resmi penyedia layanan memiliki karakteristik seperti ditunjukkan pada Gambar 4.3, dimana 252.246 (88,80%) data menggunakan pengaturan bahasa Indonesia, 13.402 (4,72%) tidak menentukan pengaturan bahasa, 12.486 (4,40%) menggunakan bahasa Inggris, dan 5.932 (2,09%) menggunakan bahasa lainnya.



Gambar 4.3. Pengaturan bahasa yang digunakan pengguna

Dalam penelitian ini sendiri hanya memanfaatkan data berbahasa Indonesia saja, sehingga total data yang selanjutnya dipergunakan adalah sesuai dengan jumlah data *tweet* dengan pengaturan bahasa Indonesia tersebut, yaitu berjumlah 252.246 *tweet*.

Beberapa akun Twitter selain akun resmi penyedia layanan dalam data yang dikumpulkan ditengarai merupakan akun bot atau akun *dummy*, dimana pada akun-akun ini secara individual memiliki jumlah pesan yang sangat besar, berisikan pesan yang sama dan memuat konten promosi terkait fitur atau *event* yang sedang dilakukan oleh salah satu penyedia layanan. Contoh akun *dummy* tersebut dapat dilihat pada Tabel 4.1.

Tabel 4.1. Contoh akun dummy dalam data

| Username | Jumlah Tweet | Tweet Duplikasi |
|-----------------|--------------|--|
| yooncheonsajj | 2745 | @jntexpressid Hai min pilih aku yaaa, aku uda nge stan seventeen dari 2017 tapi uang ku belum cukup buat beli carbong πππ Aku pengen bgt punya carbong, kalo aku menang aku bakal jaga baik2 kok😊❤️ #SARANGHAEJNT #SARANGHAEJNT #SARANGHAEJNT #SARANGHAEJNT #SARANGHAEJNT 3468 |
| arfiandims | 2672 | @jntexpressid Lagu Favorit Twice aku FEEL SPECIAL min, gak tahu kenapa pas dengar ini langsung semangat. #SARANGHAEJNT #SARANGHAEJNT #SARANGHAEJNT #SARANGHAEJNT #SARANGHAEJNT #SARANGHAEJNT #SARANGHAEJNT #SARANGHAEJNT #SARANGHAEJNT 1367 |
| our_smileflower | 2513 | @jntexpressid SUDAH JELAS ALASANNYA KARENA AKU SELALU MILIH JNT KALO SOAL PENGIRIMAN & AKU BELUM PUNYA CARAT BONG MINNN TOLONG LAHHHH 😊 #SARANGHAEJNT #SARANGHAEJNT #SARANGHAEJNT #SARANGHAEJNT #SARANGHAEJNT #SARANGHAEJNT #SARANGHAEJNT 380 |
| maghfirah188 | 2347 | @jntexpressid Semua lagu SEVENTEEN tu enak banget Min. Kalo mau yg heboh2 HIT, Getting Closer, Happy Ending. Tapi kalo untuk yg melow2 gitu enaknya dengerin lagu Pinwheel, Kidult, I |

| Username | Jumlah Tweet | Tweet Duplikasi |
|------------|--------------|---|
| | | Wish, sama Fallin' Flower. Ini tu lagu wajib aku sebelum tidur juga min☺💎❤️ #SARANGHAEJNT #SARANGHAEJNT 130 |
| lighthan02 | 1924 | @jntexpressid knp harus pilih aku? karena aku sayang Sebong dan j&t ekspres❤️ #SARANGHAEJNT *774 |

Data *tweet* dari akun *dummy* ini dapat mempengaruhi analisis karena tidak merepresentasikan pelanggan yang sesungguhnya. Oleh sebab itu *tweet* duplikat dari akun yang sama tersebut perlu dihilangkan. Meskipun *tweet* ini memuat teks terduplikasi, namun *tweet-tweet* ini juga memuat konten angka yang berbeda, sehingga proses eliminasi data *tweet* duplikasi tersebut lebih efektif bila dilakukan pada tahap data *preprocessing*, yaitu setelah proses data *cleansing*.

4.2 Data Preprocessing

Langkah pertama data *preprocessing* dimulai dengan data *cleansing*, dimana pada tahapan ini data diubah ke dalam format huruf kecil kemudian dibersihkan dari *tweet-tweet* yang hanya memuat satu (1) kata, kode program html (*web code*) yang mungkin saja belum terfilter sempurna, menghilangkan simbol dan tanda baca, menghapus *hashtag*, *mention*, *link*, menghilangkan angka dari kata atau kalimat, menghilangkan tautan web site, menghapus kata yang terdiri dari satu huruf, mengganti multipel spasi dan tab dengan spasi tunggal.

Selanjutnya adalah menghapus *tweet* terduplikasi dari akun yang sama dan proses klasifikasi terhadap akun *dummy* yang dilakukan secara manual dengan melihat konten pesan yang ditulis. Dengan metode ini dapat diketahui bahwa akun yang ditengarai sebagai akun *dummy* setelah proses penghapusan pesan-pesan duplikasi adalah akun yang memiliki jumlah *tweet* lebih dari 104 kali dan beberapa akun lain yang memiliki jumlah *tweet* kurang dari angka tersebut namun masih ditengarai sebagai akun *dummy*. *Tweet* yang berasal dari akun-akun ini selanjutnya tidak ikut sertakan dalam analisis. Setelah proses penghapusan *tweet* duplikasi dan *tweet* akun *dummy* selesai dilakukan, proses data *cleansing* dilanjutkan dengan tahap tokenisasi data yaitu memisahkan kalimat maupun kata di dalamnya secara individual untuk keperluan data *preprocessing* lebih lanjut.

Perubahan format data dari bentuk asal, pada proses *cleansing*, dan pada proses tokenisasi dapat dilihat pada Tabel 4.2.

Tabel 4.2. Contoh data hasil proses data *cleansing* dan tokenisasi

| <i>Tweet</i> | <i>Clean Tweet</i> | <i>Token Tweet</i> |
|---|--|--|
| @PosIndonesia cek dm ya. Makasih | cek dm ya makasih | [cek, dm, ya, makasih] |
| @PosIndonesia mohon dm direspon | mohon dm direspon | [mohon, dm, direspon] |
| @PosIndonesia Min paketanku ko lama ya? https://t.co/xqwgkdoraE | min paketanku ko lama ya | [min, paketanku, ko, lama, ya] |
| @sicepat_ekspres Resi No 000178369880 kenapa selalu statusnya unpick? status pengiriman "Paket gagal diambil sigesit Akmaludin Azam?" | esi no kenapa selalu statusnya unpick status pengiriman paket gagal diambil sigesit akmaludin azam | [resi, no, kenapa, selalu, statusnya, unpick, status, pengiriman, paket, gagal, diambil, sigesit, akmaludin, azam] |
| @sicepat_ekspres min kalau criss cross itu knp ya :(paketku ga sampe2 | min kalau criss cross itu knp ya paketku ga sampe | [min, kalau, criss, cross, itu, knp, ya, paketku, ga, sampe] |

Dari Tabel 4.2 tersebut terlihat bahwa *mention*, tanda baca, tautan laman web, dan angka pada kolom '*Tweet*' telah dihapus dan semua huruf dalam kolom tersebut telah diubah menjadi huruf kecil seperti ditunjukkan pada kolom '*Clean Tweet*'. Kolom '*Token Tweet*' memperlihatkan bahwa setiap baris kalimat telah dipisahkan menggunakan tanda '[' dan tiap kata di masing-masing kalimat telah terpisah dengan tanda koma (','), yang menandakan proses tokenisasi telah berhasil diaplikasikan.

Selanjutnya adalah tahap normalisasi atau tahap penyeragaman data, yaitu mengubah kata tidak baku menjadi kata baku. Tahap ini menggunakan masukan kamus lokal yaitu daftar kata tidak baku ke kata baku yang dibuat secara manual berdasarkan observasi data. Pembuatan kamus lokal ini disinkronisasikan dengan sumber leksikon, sehingga tidak semua kata dirujuk pada kata bakunya. Adapun dalam pembuatan kamus lokal ini hanya memperhitungkan kata yang memiliki kemunculan lebih dari 5 kali, sehingga kata yang muncul kurang dari nilai tersebut akan tetap dalam bentuk aslinya meskipun telah melalui proses normalisasi.

Tabel 4.3 merupakan contoh hasil pengolahan data pada proses normalisasi, dimana seperti terlihat pada kata-kata tidak baku 'makasih' diubah menjadi 'terima kasih', 'direspon' menjadi 'direspons', 'min' menjadi 'admin', 'no' menjadi 'nomor', 'sampe' menjadi 'sampai', dan seterusnya. Sedangkan beberapa seperti kata '*unpick*' yang berarti

barang belum diambil kurir dan ‘dm’ yang merupakan singkatan dari ‘*direct message*’, yang juga merupakan kata tidak baku, tidak diubah karena kata tersebut merupakan istilah unik yang dipergunakan secara konsisten dalam proses pengiriman barang dan telah dimasukkan dalam daftar kata sumber leksikon.

Tabel 4.3. Contoh data hasil proses normalisasi

| <i>Token Tweet</i> | <i>Normalize Tweet</i> |
|--|---|
| [cek, dm, ya, makasih] | [periksa, dm, ya, terima, kasih] |
| [mohon, dm, direspon] | [mohon, dm, direspons] |
| [min, paketanku, ko, lama, ya] | [admin, paketanku, kok, lama, ya] |
| [resi, no, kenapa, selalu, statusnya, unpick, status, pengiriman, paket, gagal, diambil, sigesit, akmaludin, azam] | [resi, nomor, kenapa, selalu, statusnya, unpick, status, pengiriman, paket, gagal, diambil, sigesit, akmaludin, azam] |
| [min, kalau, criss, cross, itu, knp, ya, paketku, ga, sampe] | [admin, kalau, criss, cross, itu, kenapa, ya, paketku, tidak, sampai] |

Setelah proses normalisasi data selesai dilakukan, tahap data *preprocessing* selanjutnya adalah proses *stopword removal*, dimana kata dalam kalimat yang masuk dalam daftar *stopword* akan dihapus. Tabel 4.4 merupakan contoh hasil pengolahan data pada proses *stopword removal*. Dari tabel tersebut dapat dilihat, kata seperti ‘ya’, ‘admin’, ‘resi’, ‘nomor’, dan ‘itu’ dihapus dari kalimat karena merupakan kata *stopword*.

Tabel 4.4. Contoh data hasil proses *stopword removal*

| <i>Normalize Tweet</i> | <i>Stopword Removal</i> |
|---|---|
| [periksa, dm, ya, terima, kasih] | [periksa, dm, terima, kasih] |
| [mohon, dm, direspons] | [mohon, dm, direspons] |
| [admin, paketanku, kok, lama, ya] | [paketanku, kok, lama] |
| [resi, nomor, kenapa, selalu, statusnya, unpick, status, pengiriman, paket, gagal, diambil, sigesit, akmaludin, azam] | [kenapa, statusnya, unpick, status, pengiriman, paket, gagal, diambil, akmaludin, azam] |
| [admin, kalau, criss, cross, itu, kenapa, ya, paketku, tidak, sampai] | [criss, cross, kenapa, paketku, tidak, sampai] |

Proses selanjutnya adalah proses *stemming*, dimana semua kata yang memiliki imbuhan dikembalikan dalam bentuk dasarnya dengan menggunakan pustaka Python Sastrawi. Dari Tabel 4.5 dapat dilihat beberapa kata seperti ‘direspons’ berubah ke dalam kata dasarnya yaitu ‘respons’, ‘paketanku’ menjadi ‘paket’, ‘statusnya’ menjadi ‘status’, ‘pengiriman’ menjadi ‘ kirim’, dan seterusnya.

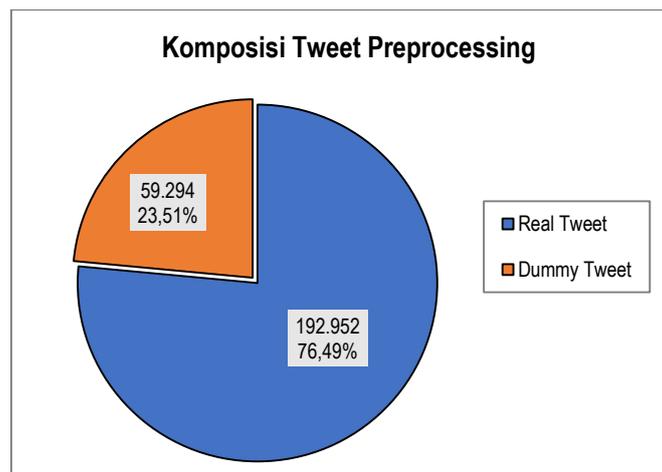
Tabel 4.5. Contoh data hasil proses *stemming*

| <i>Stopword Removal</i> | <i>Stemming</i> |
|---|---|
| [periksa, dm, terima, kasih] | [periksa, dm, terima, kasih] |
| [mohon, dm, direspons] | [mohon, dm, respons] |
| [paketanku, kok, lama] | [paket, kok, lama] |
| [kenapa, statusnya, unpick, status, pengiriman, paket, gagal, diambil, akmaludin, azam] | [kenapa, status, unpick, status, kirim, paket, gagal, ambil, akmaludin, azam] |
| [criss, cross, kenapa, paketku, tidak, sampai] | [criss, cross, kenapa, paket, tidak, sampai] |

Contoh perbandingan format data sebelum dan setelah seluruh tahapan proses data *preprocessing* dilakukan dapat dilihat pada Tabel 4.6.

Tabel 4.6. Format data sebelum dan sesudah *preprocessing*

| <i>Sebelum Preprocessing</i> | <i>Setelah Preprocessing</i> |
|--|---|
| @PosIndonesia cek dm ya. Makasih | periksa dm terima kasih |
| @PosIndonesia mohon dm direspon | mohon dm respons |
| @PosIndonesia Min paketanku ko lama ya? https://t.co/xqwgkdoraE | paket kok lama |
| @sicepat_ekspres Resi No 000178369880 kenapa selalu statusnya unpick? status pengiriman "Paket gagal diambil sigesit Akmaludin Azam?" | kenapa status unpick status kirim paket gagal ambil akmaludin azam |
| @sicepat_ekspres min kalau criss cross itu knp ya :(paketku ga sampe2 | criss cross kenapa paket tidak sampai |

Gambar 4.4. Komposisi *tweet preprocessing*

Setelah keseluruhan prosedur *preprocessing* dilalui, data yang dapat dipergunakan lebih lanjut untuk analisis sentimen dan pemodelan topik adalah berjumlah 192.952 data atau

76,49% dari keseluruhan data yang masuk pada tahap *preprocessing*. Dari jumlah ini dapat diketahui juga bahwa jumlah *tweet* duplikasi dan *tweet* yang berasal dari akun *dummy* cukup tinggi, yakni 59.294 data atau 23,51%. Komposisi data tersebut secara visualisasi ditunjukkan pada Gambar 4.4.

4.3 Klasifikasi Data Latih

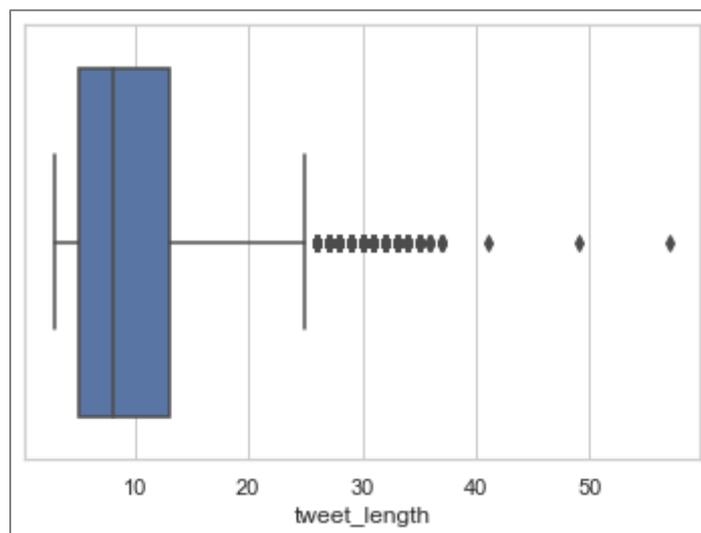
Seperti telah disebutkan dalam bab sebelumnya, tahap klasifikasi data latih dilakukan dengan menggunakan pendekatan metode leksikal, dimana sumber leksikal yang menjadi acuan dalam menentukan polaritas data diadopsi dari sumber leksikal yang dikembangkan oleh Koto & Rahmaningtyas (2017). Jumlah data sumber leksikon yang diadaptasi dari penelitian ini berjumlah 1319 kata yang terdiri dari 993 kata memiliki skor sentimen negatif dan 326 kata memiliki skor sentimen positif. Jumlah ini didapatkan dengan *me-lookup* kata dalam sumber leksikon dan disinkronisasikan dengan kata yang ada dalam data latih. Contoh kata yang ada dalam sumber leksikon ini dapat dilihat pada Tabel 4.7.

Tabel 4.7. Contoh kata sentimen dalam sumber leksikon

| Kata | Skor Sentimen | Kata | Skor Sentimen |
|---------|---------------|---------|---------------|
| bangga | 2 | jelek | -3 |
| bersih | 2 | jengkel | -3 |
| beres | 3 | hilang | -4 |
| percaya | 5 | hancur | -5 |
| top | 5 | lambat | -3 |

Tahap klasifikasi data latih dimulai dengan melakukan proses sampling terhadap data yang dihasilkan dari tahap *preprocessing* sebelumnya. Agar data yang diambil sebagai data latih semaksimal mungkin dapat mewakili keseluruhan data, maka data yang dipergunakan sebagai dasar pengambilan sampel acak dibatasi pada data teks yang memiliki 3-25 kata. Pengambilan data ini didasarkan pada distribusi jumlah kata per kalimat dari data yang dianalisis, seperti yang ditunjukkan pada

Gambar 4.5, dimana kalimat yang terdiri hanya 2 kata memiliki akurasi inferensi yang rendah jika dijadikan data latih, sedangkan kalimat yang terdiri lebih dari 25 kata adalah data yang tergolong memiliki kemungkinan sangat kecil untuk terjadi (*outlier*) jika diukur dengan sebaran distribusi normal.



Gambar 4.5. Batasan pengambilan sampel data latih (*boxplot* distribusi data)

Sampel diambil dengan metode *stratified random sampling*, dimana variabel ‘*origin*’ dan ‘*month*’ dijadikan basis pemilihan sampel. Penelitian-penelitian terdahulu memiliki jumlah data latih yang bervariasi dalam pembuatan model klasifikasi, namun demikian semakin besar jumlah data latih yang dipergunakan akan meningkatkan akurasi dari model yang dibuat.

Adapun dalam penelitian ini jumlah data yang dipergunakan sebagai data latih adalah $\pm 10,000$ data. Jumlah ini dipilih karena masih memungkinkan bagi peneliti untuk mengevaluasi hasil klasifikasi secara manual sebelum diaplikasikan untuk menentukan polaritas sentimen keseluruhan data. Jumlah data ini dapat diubah (ditambah) jika dalam proses pengujian dan validasi memberikan hasil akurasi yang rendah.

Proses selanjutnya adalah ekstraksi fitur, dimana data setiap kalimat dinilai berdasarkan bobot kata yang menjadi fitur sentimen. Skor setiap kalimat merupakan jumlah total bobot dari kata fitur sentimen ini. Sebagai contoh adalah kalimat ‘tolong difollow up belum sampai sampai’, kata bersentimen dalam sumber leksikon untuk kalimat ini adalah kata ‘tolong’ dengan skor -5 dan ‘sampai’ dengan skor +1, sedangkan kata ‘belum’ merupakan kata negasi. Sesuai dengan algoritma ekstraksi fitur yang dipergunakan, kata bersentimen yang diawali negasi akan bernilai kebalikan dengan penambahan 1 poin, sehingga untuk kalimat ini mendapatkan skor total $-5 + (-(1+1)) + 1 = -6$. Adapun kata ‘terima kasih’ dalam penelitian ini tidak dimasukkan ke dalam kata bersentimen karena

tersebut tidak menunjukkan apresiasi tetapi lebih merupakan ‘pemanis’ dalam penyampaian pesan bahkan pada penyampaian keluhan saja.

Contoh proses ekstraksi fitur untuk beberapa data lainnya dengan pendekatan leksikon ini dapat dilihat pada Tabel 4.8.

Tabel 4.8. Contoh ekstraksi fitur dan perhitungan skor sentimen

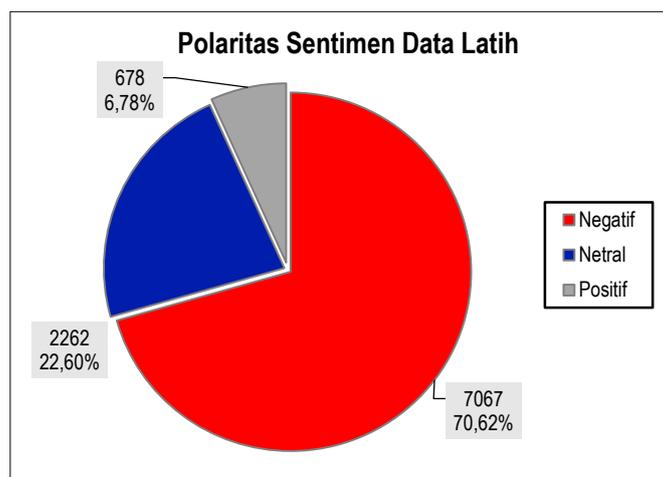
| <i>Normal Tweet</i> | Fitur | Skor |
|---|--|-------------|
| jasa pengiriman terbaik | terbaik = 3 | 3 |
| tolong difollow up belum sampai sampai | tolong = -5 belum_sampai = -(1+1) sampai = 1 | -6 |
| tolong dengarkan keluhan masyarakat | tolong = -5 keluhan = -3 | -8 |
| mohon respons terima kasih | mohon = -5 respons = 1 | -4 |
| aku sudah telepon pak kurir yang biasa kirim ke rumah | sudah = -1 kirim = 1 | 0 |

Hasil yang diharapkan dalam tahap klasifikasi data latih ini adalah polaritas ‘Positif’, ‘Netral’, dan ‘Negatif’. *Tweet* dikatakan memiliki polaritas ‘Positif’ apabila data yang bersangkutan tersebut memiliki skor sentimen secara keseluruhan lebih besar dari nol (>0), sedangkan *tweet* dikatakan memiliki polaritas ‘Negatif’ apabila data tersebut memiliki skor kurang dari nol (<0). *Tweet* yang memiliki skor sama dengan nol adalah *tweet* yang memiliki polaritas sentimen ‘Netral’. Sehingga dari hasil klasifikasi yang diharapkan tersebut, maka pendekatan metode *rule based* dipergunakan dalam proses pengelompokan polaritas ini. Contoh klasifikasi menggunakan metode *rule based* ini dapat dilihat pada Tabel 4.9.

Tabel 4.9. Contoh hasil klasifikasi data latih dengan pendekatan *rule based*

| <i>Normal Tweet</i> | Skor | Klasifikasi |
|---|-------------|--------------------|
| jasa pengiriman terbaik | 3 | Positif |
| tolong difollow up belum sampai sampai | -6 | Negatif |
| tolong dengarkan keluhan masyarakat | -8 | Negatif |
| mohon respons terima kasih | -4 | Negatif |
| aku sudah telepon pak kurir yang biasa kirim ke rumah | 0 | Netral |

Setelah seluruh data latih terklasifikasi sesuai dengan polaritas sentimen masing-masing, klasifikasi data latih dilanjutkan dengan proses evaluasi hasil secara manual dengan melihat kecocokan klasifikasi metode dengan klasifikasi yang diharapkan. Beberapa data yang memiliki hasil tidak sesuai dengan harapan selanjutnya diklasifikasikan secara manual. Adapun hasil klasifikasi data latih yang didapatkan pada akhir proses adalah 7.067 (70,62%) data memiliki polaritas sentimen ‘Negatif’, 2.262 (22,60%) ‘Netral’, dan 678 (6,78%) ‘Positif’ seperti ditunjukkan pada Gambar 4.6.

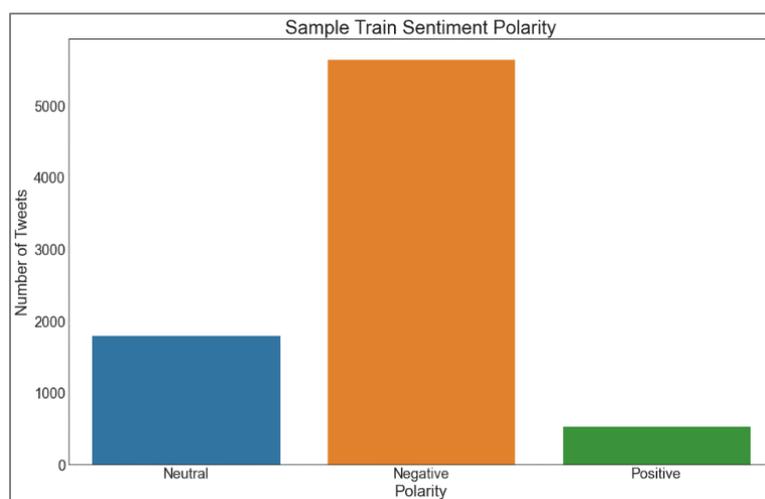


Gambar 4.6. Polaritas sentimen data latih

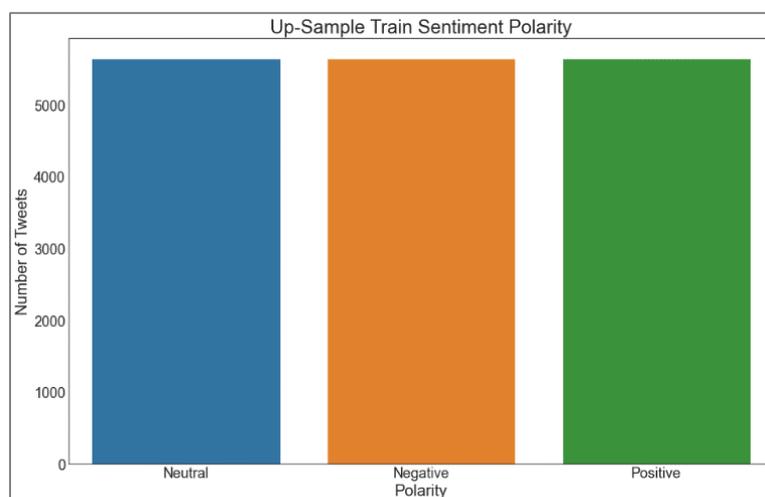
4.4 Klasifikasi Keseluruhan Data

Seperti telah dijelaskan dalam metode penelitian, tahapan klasifikasi sentimen untuk keseluruhan data dalam penelitian ini menggunakan pendekatan statistik dimana metode yang dipergunakan adalah TF-IDF dalam proses ekstraksi fitur dan SVM sebagai pengklasifikasinya. Langkah pertama dalam proses klasifikasi data dengan pendekatan ini adalah pembuatan model klasifikasi dengan menggunakan data latih yang telah dibuat dalam tahap sebelumnya. Seperti telah diketahui, data latih yang telah diklasifikasi memiliki populasi polaritas sentimen yang jauh berbeda yaitu polaritas sentimen ‘Negatif’ 70,62%, ‘Netral’ 22,60%, dan ‘Positif’ 6,78%. Data latih yang memiliki jumlah populasi kelas yang jauh berbeda dapat menyebabkan *overfitting/underfitting* pada model yang dibuat sehingga perlu dilakukan data *balancing* (penyeimbangan). Proses pelatihan model klasifikasi dalam penelitian ini menggunakan proporsi *training* dan *test* 80:20, dimana 80% data latih dijadikan data untuk pelatihan model (*training*) dan 20% sisanya dipergunakan sebagai data pengujian (*testing*). Proses pembagian *training* dan *testing* data memanfaatkan pustaka Python Sklearn modul `model_selection.train_test_split`.

Adapun berdasarkan pembagian proporsi 80:20 terhadap data latih diperoleh 8.005 data ditetapkan sebagai data *training* ('Negatif' = 5.653, 'Netral' = 1.810, 'Positif' = 542) dan 2.002 ditetapkan sebagai data testing ('Negatif' = 1.414, 'Netral' = 452, 'Positif' = 136). Proses penyeimbangan data hanya dilakukan terhadap data *training*, dimana perbandingan data sebelum dan sesudah proses data *balancing* dapat dilihat pada Gambar 4.7 dan Gambar 4.8.



Gambar 4.7. Komposisi data *training* sebelum proses *balancing*



Gambar 4.8. Komposisi data *training* sesudah proses *balancing*

Setelah data *training* diseimbangkan, proses pelatihan model dapat dilakukan. Keseluruhan proses pelatihan model menggunakan pustaka Python Sklearn, dimana pada proses ekstraksi fitur TF-IDF memanfaatkan modul *feature_extraction.TfidfVectorizer* sedangkan proses klasifikasi SVM memanfaatkan modul *svm.LinearSVC*. Hasil pelatihan model pada penelitian ini dapat dilihat pada matriks *confusion* Tabel 4.10.

Tabel 4.10. *Confusion matrix* hasil pelatihan model klasifikasi

| | | Kelas Prediksi | | |
|------------------|----------|----------------|---------|----------|
| | | Negative | Neutral | Positive |
| Kelas Sebenarnya | Negative | 1303 | 86 | 25 |
| | Neutral | 46 | 378 | 28 |
| | Positive | 8 | 23 | 105 |

Tabel 4.10 merupakan perbandingan kelas data sebenarnya dibandingkan dengan kelas yang diprediksi oleh model TF-IDF SVM yang dipergunakan. Dari tabel ini dapat diketahui jumlah data yang diprediksi untuk setiap kelas sentimen, dimana dari 2.002 total data pengujian, model klasifikasi secara tepat dapat memprediksi kelas sentimen ‘Negatif’ = 1.303 data, kelas sentimen ‘Negatif’ terprediksi ‘Netral’ = 86 data, dan kelas sentimen ‘Negatif’ terprediksi ‘Positif’ = 25 data. Kelas sentimen ‘Netral’ diprediksi secara tepat = 378 data, terprediksi ke dalam kelas sentimen ‘Negatif’ = 46 data, dan ‘Positif’ = 28 data. Untuk kelas sentimen ‘Positif’ dapat diprediksi secara tepat = 105 data, terprediksi ke dalam kelas sentimen ‘Negatif’ = 8 data, dan ‘Netral’ = 23 data.

Berdasarkan Tabel 4.10, nilai akurasi, presisi, *recall*, dan *f1-score* yang diperoleh dalam pembuatan model TF-IDF SVM ini dapat diketahui dengan menghitung masing-masing parameter. Sesuai dengan Persamaan 3.2, maka nilai akurasi yang dapat dicapai oleh model adalah sebagai berikut:

$$Accuracy = \frac{1303 + 378 + 105}{2002} = \frac{1786}{2002} = 0,8921$$

Parameter akurasi memperlihatkan nilai yang cukup tinggi, dimana model klasifikasi mampu bekerja dengan baik dalam memprediksi sentimen secara tepat yaitu 89,21% dari keseluruhan data pengujian. Penilaian kualitas klasifikasi ini didasarkan pada batasan kualitas klasifikasi (Dewi, 2016) dan penelitian-penelitian serupa yang memperoleh nilai akurasi yang mirip bahkan lebih rendah, contoh pengujian model dalam penelitian yang dikerjakan oleh Zulkarnain, Surjandari, & Wayasti (2018) memperoleh akurasi 86%, penelitian Rus, Annisa, Surjandari, & Zulkarnain (2019) dengan akurasi maksimum 81%.

Untuk melihat ketepatan klasifikasi untuk masing-masing kelas sentimen, perhitungan nilai presisi, *recall*, dan *f1-score* untuk masing-masing kelas sentimen perlu dilakukan. Berdasarkan Persamaan 3.3 – 3.5 untuk perhitungan nilai presisi, Persamaan 3.6 – 3.8

untuk perhitungan nilai *recall*, dan Persamaan 2.5 untuk perhitungan nilai *f-score*, maka perhitungan nilai presisi, *recall*, dan *f1-score* tersebut dapat dilihat pada *Tabel 4.11*.

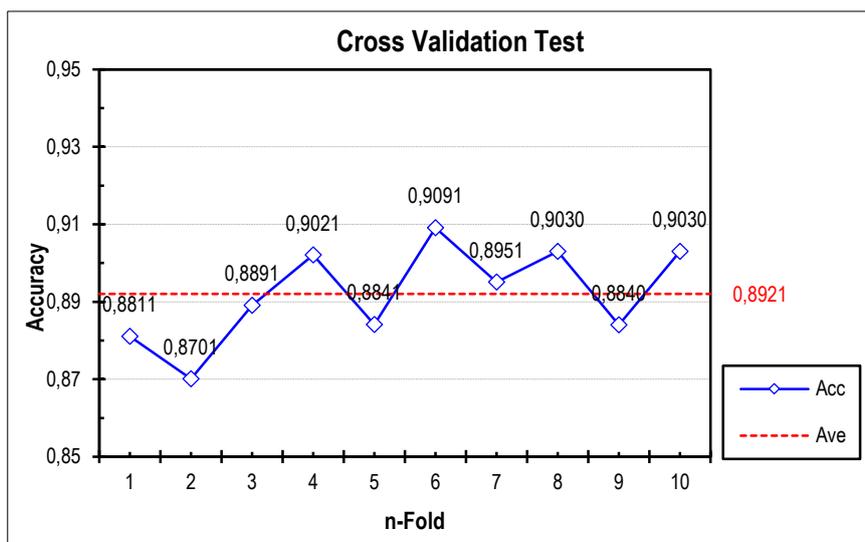
Tabel 4.11. Hasil perhitungan presisi, *recall*, dan *f1-score* kelas sentimen

| Kelas Sentimen | Parameter | | |
|----------------|-----------|---------------|-----------------|
| | Presisi | <i>Recall</i> | <i>f1-score</i> |
| Negatif | 0,9602 | 0,9215 | 0,9405 |
| Netral | 0,7762 | 0,8363 | 0,8051 |
| Positif | 0,6646 | 0,7721 | 0,7143 |

Hasil perhitungan untuk keseluruhan parameter pengujian menunjukkan bahwa model telah memberikan hasil yang sangat baik khususnya dalam mengklasifikasi kelas sentimen ‘Negatif’, dimana kelas memperoleh nilai presisi = 0,9602, *recall* = 0,9215, dan *f1-score* = 0,9405. Kelas sentimen ‘Netral’ memperoleh hasil pengujian lebih rendah dibandingkan kelas sentimen ‘Negatif’, yaitu presisi = 0,7762, *recall* = 0,8363, dan *f1-score* = 0,8051. Kelas sentimen ‘Positif’ memperoleh hasil pengujian yang paling rendah di antara kelas sentimen yang lain dengan nilai presisi = 0,6646, *recall* = 0,7721, dan *f1-score* = 0,7143.

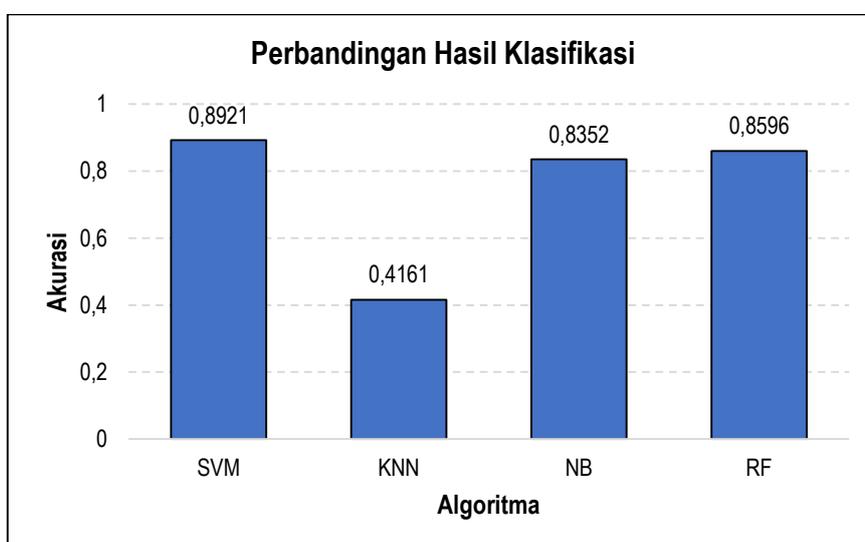
Meskipun memiliki hasil uji yang tidak sama untuk masing-masing kelas sentimen, berdasarkan nilai uji terendah yang dapat dicapai oleh model masih menunjukkan performa klasifikasi yang baik (presisi > 0,65) dan dapat diandalkan dalam proses generalisasi (*recall* > 0,75). Berdasarkan hasil uji yang diperoleh tersebut, dapat diartikan bahwa model klasifikasi TF-IDF SVM yang dipergunakan juga telah sesuai untuk karakteristik data yang ada.

Hasil pengujian yang telah dilakukan sebelumnya merupakan hasil uji berdasarkan satu set kelompok data saja yaitu data *training* dan data *testing*. Untuk dapat mengetahui kemampuan klasifikasi model terhadap data kelompok data yang lain atau proses validasi perlu dilakukan karena tugas utama model yang dibuat adalah mengklasifikasikan data baru berdasarkan kelas sentimen yang sesuai. Dalam penelitian ini, proses validasi model memanfaatkan metode validasi *10-fold cross validation* dimana metode ini memiliki keuntungan yaitu dapat memvalidasi model tanpa membutuhkan data tambahan. Dengan membagi data latih ke dalam 10 sub-set kelompok data *training* dan data *testing* yang berbeda, hasil pengujian terhadap masing-masing sub-set ditunjukkan pada Gambar 4.9.



Gambar 4.9. Hasil uji model dengan *10-fold cross validation*

Gambar 4.9 menyajikan hasil validasi terhadap model yang telah dibuat menggunakan 10 *sub-set* data yang berbeda memberikan akurasi yang tinggi, dimana model memiliki performa klasifikasi dengan akurasi terendah adalah 0,8701, tertinggi adalah 0,9091, dan rata-rata 0,8921.

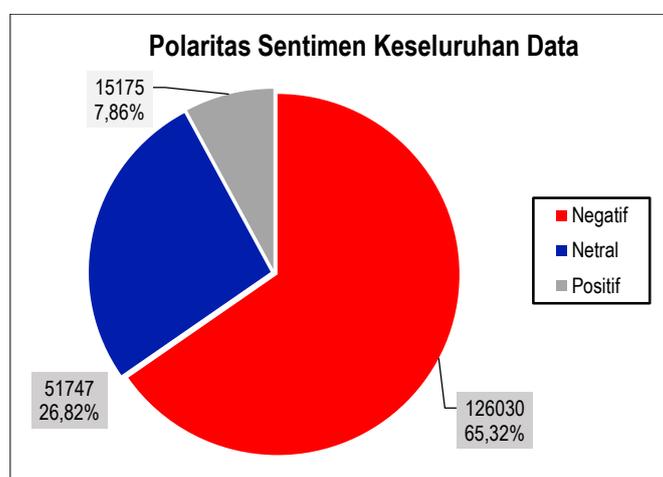


Gambar 4.10. Perbandingan akurasi beberapa metode klasifikasi

Gambar 4.10 menyajikan perbandingan hasil akurasi beberapa metode klasifikasi statistika yang populer dan juga sering dipergunakan dalam proses klasifikasi analisis sentimen. Perbandingan akurasi beberapa metode klasifikasi ini memberikan hasil bahwa metode klasifikasi SVM merupakan metode yang dapat dipergunakan dan paling sesuai untuk mengklasifikasi data yang dimiliki. Hasil perbandingan akurasi ini menempatkan

metode SVM sebagai metode klasifikasi dengan nilai tertinggi 0,8921; metode klasifikasi RF pada urutan kedua dengan nilai 0,8596; metode NB pada urutan ketiga dengan nilai 0,8352; dan metode KNN dengan nilai akurasi terendah yaitu 0,4161.

Setelah proses validasi model dan perbandingan metode klasifikasi telah selesai dilakukan, selanjutnya klasifikasi kelas sentimen terhadap keseluruhan data dapat dilakukan dengan *men-deploy* atau melakukan inferensi model terhadap keseluruhan data. Proses yang dipergunakan mirip dengan proses model testing, hanya saja data testing dalam langkah ini digantikan dengan keseluruhan data yang diperoleh pada tahap *preprocessing* dengan tujuan untuk dapat memprediksi kelas sentimen keseluruhan data tersebut.



Gambar 4.11. Polaritas sentimen keseluruhan data

Hasil klasifikasi polaritas sentimen keseluruhan data ditunjukkan oleh Gambar 4.11. Hasil klasifikasi sentimen ini memiliki kemiripan dengan klasifikasi polaritas sentimen data latih yang dipergunakan, dimana kelas sentimen 'Negatif' mendominasi kelas sentimen keseluruhan data dengan proporsi yang sedikit berbeda. Hal ini menunjukkan bahwa secara umum, *tweet* yang disampaikan dalam rentang waktu Oktober 2019 hingga September 2020 tersebut mayoritas merupakan keluhan atau ketidakpuasan pengguna atas layanan yang diberikan oleh penyedia layanan yang bersangkutan. Adapun proporsi kelas sentimen yang didapatkan dari keseluruhan ini masing-masing adalah kelas sentimen 'Negatif' = $126.030/192.952$ data atau 65,32% dari keseluruhan data, kelas sentimen 'Netral' = $51.747/192.952$ data atau 26,82% dari keseluruhan data, dan kelas sentimen 'Positif' = $15.175/192.952$ data atau 7,86% dari keseluruhan data.

Contoh data yang terklasifikasi memiliki polaritas sentimen ‘Negatif’ dapat dilihat pada Tabel 4.12. Contoh data yang terklasifikasi memiliki polaritas sentimen ‘Netral’ dapat dilihat pada Tabel 4.13. Sedangkan Tabel 4.14 menunjukkan contoh data yang terklasifikasi memiliki polaritas ‘Positif’.

Tabel 4.12. Contoh data terklasifikasi 'Negatif'

| Indeks | Tweet Normalisasi |
|---------------|--|
| 55527 | sampai sekarang tidak ada pergerakannya |
| 56658 | jp admin ini tertahan lama banget mohon diproses |
| 104571 | tanya dong paket saya kok belum tiba ya memeriksa resi kok berhenti tidak jalan |
| 19837 | periksa dm saya juga admin |
| 67468 | kak maaf saya mau tanya paket saya kenapa status pengirimannya tertahan di jakarta gateway ya dari april sampai sekarang april tidak ada perubahan |
| 91163 | barang saya hilang apa dimana pak bagaimana proses selanjutnya |
| 126147 | giliran pujian dijawab komplain tidak dilayani ini paket saya dari tanggal tidak ada pergerakan ini bagaimana |
| 64958 | admin mohon bantuannya untuk pelacakan paket jp karena tidak update thanks |
| 16517 | tolong diperiksa juragan masa sudah berhari pickup gagal terus terima kasih |
| 19598 | admin bagaimana update komplain ini |

Tabel 4.13. Contoh data terklasifikasi 'Netral'

| Indeks | Tweet Normalisasi |
|---------------|--|
| 141934 | admin apakah amp menyediakan bumble warp soalnya saya mau melakukan pengembalian barang di shopee |
| 151716 | badan men muka penakut |
| 171634 | kalau menang hpnya buat kasih ke ibu dupaya bisa komunikasi terus selama saya kuliah di luar kota jadi bisa komunikasi dengan lancar |
| 134053 | judul lagu lathi penyanyi aneh genius feat sara fajira mari ikutan sobat |
| 157125 | bisa jadi |
| 196891 | alat yuk ikutan |
| 143547 | admin mau tanya bisa pengiriman paket emas perhiasan dan batangan ngga terima kasih |
| 30908 | tapi paketnya bukan atas nama saya bisa tidak |
| 22282 | syarat yang harus di bawa dalam pengambilan str apa saja admin |
| 1369 | kalau mau jadi agen bagaimana caranya kak |

Tabel 4.14. Contoh data terklasifikasi 'Positif'

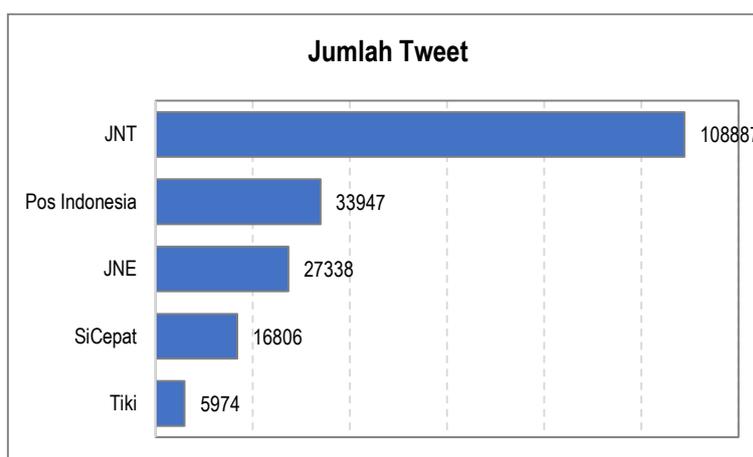
| Indeks | Tweet Normalisasi |
|---------------|---|
| 168639 | terus jaya dan selalu cepat yaa kirim paketanku |

| Indeks | <i>Tweet</i> Normalisasi |
|--------|--|
| 179372 | sudah diterima dengan baik thank you |
| 196740 | dear jnt gratis biaya kirim terus setiap saya belanja tapi sering cod an sabar dan sehat terus untuk abang kurir |
| 113883 | punyaku sehari sampai loh barusan banget |
| 166565 | semoga sukses selalu |
| 124942 | sicepat memang cepat banget murah juga terbaik sekali pokoknya |
| 35487 | hati di perjalanan ya utamakan juga keselamatan karyawannya admin semangat |
| 116311 | paket sudah sampai terima kasih banyak atas follow upnya |
| 95517 | hari ini paket mulai proses perjalanan terima kasih admin semoga tidak berhenti lagi paketannya ya admin |
| 196363 | mantap euy |

4.5 Analisis Sentimen Jendela Waktu

4.5.1 Jumlah *Tweet* Sebelum dan Selama Pandemi

Analisis sentimen jendela waktu dilakukan untuk mengetahui tren sentimen sepanjang waktu penelitian yang telah ditetapkan. Adapun data yang dipergunakan merupakan *tweet* adalah yang ditulis dalam rentang waktu Oktober 2019 hingga September 2020. Data tersebut diambil dari *tweet-tweet* yang menyebutkan akun resmi penyedia layanan yang dijadikan objek penelitian yang ditunjukkan pada Gambar 4.12, dimana JNT merupakan penyedia layanan yang paling sering disebutkan dalam *tweet* pengguna dengan 108.887 kali, Pos Indonesia disebut 33.947 kali, JNE 27.338 kali, SiCepat 16.806 kali, dan Tiki 5.974 kali.



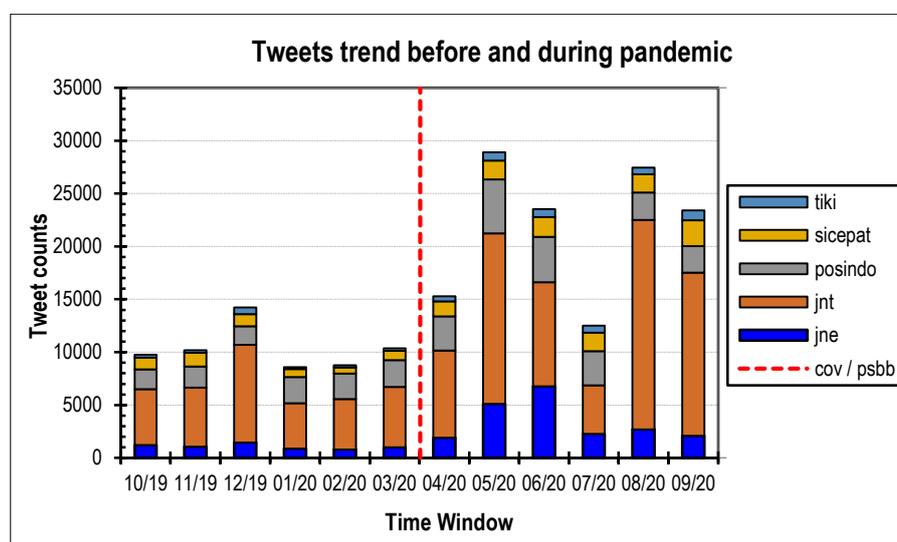
Gambar 4.12. Total Jumlah *tweet* masing-masing penyedia layanan

Salah satu tujuan penelitian ini adalah untuk mengetahui korelasi polaritas sentimen pengguna layanan berkaitan dengan pandemi covid-19, dalam hal ini variabel kebijakan

tentang penanganan pandemi menjadi parameter yang memisahkan waktu sebelum dan selama pandemi. Peraturan dan keputusan terkait penanganan dan penanggulangan pandemi covid-19 sendiri resmi diberlakukan pada 30 Maret 2020, yang disusul dengan diberlakukannya berbagai kebijakan teknis seperti psbb (pembatasan sosial berskala besar) dan pembatasan-pembatasan lainnya. Oleh sebab itu, pada penelitian ini *tweet* yang ditulis hingga bulan Maret 2020 dikelompokkan dalam *tweet* sebelum pandemi sedangkan *tweet* yang ditulisnya dikelompokkan dalam *tweet* selama pandemi.

Tabel 4.15. *Tweet* sebelum dan selama pandemi berdasarkan penyedia layanan

| Bulan | cov/psbb | JNE | JNT | PosIndo | SiCepat | Tiki |
|---------|----------|------|-------|---------|---------|------|
| 2019-10 | 0 | 1219 | 5296 | 1860 | 1128 | 265 |
| 2019-11 | 0 | 1071 | 5595 | 1987 | 1287 | 233 |
| 2019-12 | 0 | 1477 | 9210 | 1756 | 1148 | 635 |
| 2020-01 | 0 | 901 | 4280 | 2479 | 755 | 171 |
| 2020-02 | 0 | 789 | 4780 | 2422 | 574 | 189 |
| 2020-03 | 0 | 1011 | 5699 | 2525 | 900 | 241 |
| 2020-04 | 1 | 1927 | 8231 | 3216 | 1435 | 480 |
| 2020-05 | 1 | 5117 | 16128 | 5089 | 1769 | 794 |
| 2020-06 | 1 | 6763 | 9843 | 4291 | 1888 | 751 |
| 2020-07 | 1 | 2299 | 4586 | 3221 | 1752 | 653 |
| 2020-08 | 1 | 2688 | 19808 | 2591 | 1732 | 634 |
| 2020-09 | 1 | 2090 | 15427 | 2509 | 2438 | 928 |



Gambar 4.13. Tren jumlah *tweet* sebelum dan selama pandemi

Tabel 4.15 menunjukkan data jumlah *tweet* yang ditulis sebelum dan selama pandemi yang ditandai dengan penggunaan nilai 0 (nol) pada variabel ‘cov/psbb’ untuk data sebelum pandemi dan nilai 1 (satu) untuk data yang ditulis selama pandemi. Data jumlah

tweet ini secara grafis dapat dilihat pada Gambar 4.13, dimana secara sepintas terlihat bahwa jumlah *tweet* selama pandemi cenderung lebih tinggi dibandingkan jumlah *tweet* sebelum pandemi. Uji korelasi Spearman dilakukan terhadap data ini untuk mengetahui korelasi dan signifikansi perubahan yang terjadi tersebut.

Hasil uji korelasi dan signifikansi (*p-value*) Spearman yang ditunjukkan oleh Tabel 4.16 dan Tabel 4.17.

Tabel 4.16. Uji korelasi tren jumlah *tweet* vs pandemi (cov/psbb)

| | cov/psbb | JNE | JNT | PosIndo | SiCepat | Tiki |
|----------|---------------|--------|--------|---------|---------|------|
| cov/psbb | 1 | | | | | |
| JNE | 0,8690 | 1 | | | | |
| JNT | 0,5794 | 0,6993 | 1 | | | |
| PosIndo | 0,8208 | 0,7063 | 0,3706 | 1 | | |
| SiCepat | 0,8690 | 0,9021 | 0,6573 | 0,6224 | 1 | |
| Tiki | 0,7725 | 0,8671 | 0,6853 | 0,5245 | 0,9091 | 1 |

Dari kedua tabel ini dapat diketahui bahwa telah terjadi perubahan jumlah *tweet* yang signifikan sebelum dan selama pandemi diindikasikan oleh data cov/psbb berkorelasi dengan penyedia layanan (sesuai data bercetak tebal). Nilai korelasi positif antara *tweet* penyedia layanan dengan pandemi menunjukkan bahwa terjadi kenaikan jumlah *tweet* yang dilakukan selama pandemi, sedangkan signifikansi korelasi ditunjukkan dengan nilai $p\text{-value} \leq 0,05$.

Tabel 4.17. Uji signifikansi korelasi tren jumlah *tweet* vs pandemi

| | cov/psbb | JNE | JNT | PosIndo | SiCepat | Tiki |
|----------|---------------|--------|--------|---------|---------|------|
| cov/psbb | 0 | | | | | |
| JNE | 0,0002 | 0 | | | | |
| JNT | 0,0484 | 0,0114 | 0 | | | |
| PosIndo | 0,0011 | 0,0102 | 0,2356 | 0 | | |
| SiCepat | 0,0002 | 0,0001 | 0,0202 | 0,0307 | 0 | |
| Tiki | 0,0032 | 0,0003 | 0,0139 | 0,0800 | 0 | 0 |

Kenaikan jumlah *tweet* tersebut mengindikasikan bahwa memang telah terjadi kenaikan jumlah layanan/pengiriman barang yang dilakukan selama pandemi. Jika diakumulasikan, jumlah *tweet* enam bulan sebelum pandemi adalah 61.889 (32,07%), sedangkan jumlah *tweet* untuk waktu yang sama selama pandemi adalah 131.067 (67,93). Hal ini berarti bahwa kenaikan jumlah layanan/pengiriman dengan menggunakan

indikator *tweet* selama pandemi mencapai lebih dari 200% dibandingkan sebelum pandemi untuk waktu yang sama.

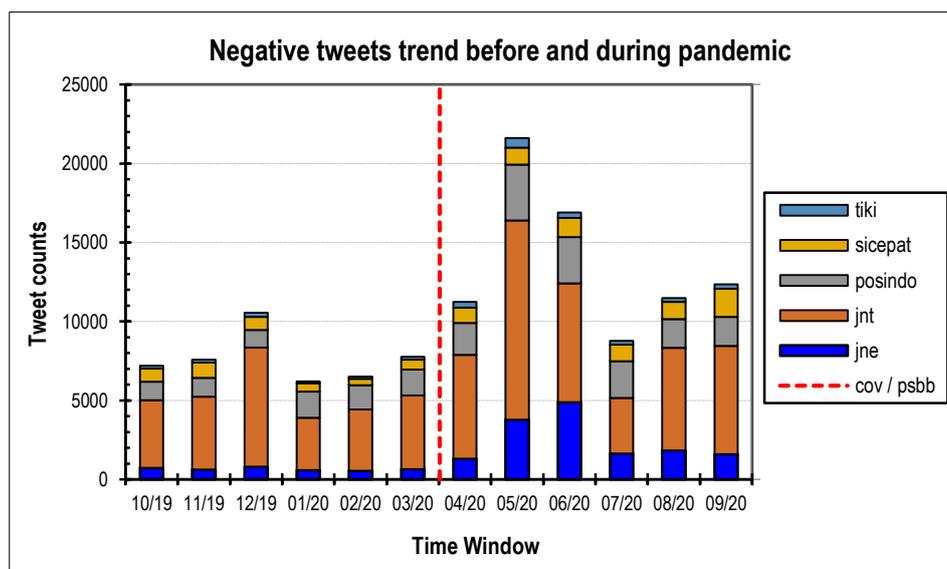
4.5.2 Polaritas Sentimen Sebelum dan Selama Pandemi

Untuk mengetahui tren polaritas sentimen pelanggan untuk masing-masing penyedia layanan sebelum dan selama pandemi, data dikelompokkan berdasarkan klasifikasi sentimen yang dimiliki. Sehingga data dibagi dalam 3 kelompok (*sub-set*), yaitu kelompok 1 - data dengan polaritas sentimen 'Negatif', kelompok 2 - data dengan polaritas sentimen 'Netral', dan kelompok 3 - data dengan polaritas sentimen 'Positif'.

Kelompok 1 – data dengan polaritas sentimen 'Negatif'

Tabel 4.18. *Tweet* 'Negatif' sebelum dan selama pandemi

| Bulan | cov/psbb | JNE | JNT | PosIndo | SiCepat | Tiki |
|---------|----------|------|-------|---------|---------|------|
| 2019-10 | 0 | 697 | 4316 | 1132 | 845 | 192 |
| 2019-11 | 0 | 629 | 4623 | 1103 | 982 | 181 |
| 2019-12 | 0 | 828 | 7641 | 1052 | 838 | 242 |
| 2020-01 | 0 | 598 | 3340 | 1581 | 543 | 126 |
| 2020-02 | 0 | 525 | 3895 | 1475 | 398 | 138 |
| 2020-03 | 0 | 614 | 4691 | 1541 | 617 | 177 |
| 2020-04 | 1 | 1308 | 6651 | 1865 | 950 | 367 |
| 2020-05 | 1 | 3709 | 12659 | 3279 | 1083 | 581 |
| 2020-06 | 1 | 4841 | 7634 | 2727 | 1199 | 329 |
| 2020-07 | 1 | 1628 | 3545 | 2131 | 1086 | 190 |
| 2020-08 | 1 | 1817 | 6079 | 1633 | 1089 | 226 |
| 2020-09 | 1 | 1590 | 6576 | 1638 | 1825 | 235 |



Gambar 4.14. *Tweet* 'Negatif' sebelum dan selama pandemi

Data dengan polaritas sentimen ‘Negatif’ sebelum dan selama pandemi ditunjukkan oleh Tabel 4.18 dan disajikan secara grafis pada Gambar 4.14. Dari Tabel 4.18 dan Gambar 4.14 secara sekilas terlihat bahwa terjadi kenaikan jumlah data yang terklasifikasi memiliki polaritas sentimen ‘Negatif’ terutama pada periode tiga bulan pertama pandemi, sedangkan pada periode tiga bulan kedua pandemi terlihat bahwa tren *tweet* ‘Negatif’ memiliki jumlah yang relatif sama dibandingkan dengan tren jumlah *tweet* sebelum pandemi. Oleh sebab itu, pengujian korelasi dan signifikansi dibedakan menjadi dua periode, yaitu periode tiga bulan pertama selanjutnya disebut periode pertama pandemi dan periode tiga bulan kedua yang selanjutnya disebut dengan periode kedua pandemi.

Tabel 4.19. Uji korelasi *tweet* ‘Negatif’ vs periode pertama pandemi

| | cov/psbb | JNE | JNT | PosIndo | SiCepat | Tiki |
|----------|---------------|--------|--------|---------|---------|------|
| cov/psbb | 1 | | | | | |
| JNE | 0,8216 | 1 | | | | |
| JNT | 0,6390 | 0,8333 | 1 | | | |
| PosIndo | 0,8216 | 0,4667 | 0,3000 | 1 | | |
| SiCepat | 0,7303 | 0,8833 | 0,6667 | 0,4167 | 1 | |
| Tiki | 0,8216 | 0,9333 | 0,8667 | 0,4333 | 0,8000 | 1 |

Hasil uji korelasi dan signifikansi polaritas sentimen ‘Negatif’ dengan pandemi covid-19 untuk periode pertama dapat dilihat pada Tabel 4.19 dan Tabel 4.20 sesuai dengan data yang tercetak tebal.

Tabel 4.20. Uji signifikansi korelasi *tweet* ‘Negatif’ vs periode pertama pandemi

| | cov/psbb | JNE | JNT | PosIndo | SiCepat | Tiki |
|----------|---------------|--------|--------|---------|---------|------|
| cov/psbb | 0 | | | | | |
| JNE | 0,0066 | 0 | | | | |
| JNT | 0,0639 | 0,0053 | 0 | | | |
| PosIndo | 0,0066 | 0,2054 | 0,4328 | 0 | | |
| SiCepat | 0,0255 | 0,0016 | 0,0499 | 0,2646 | 0 | |
| Tiki | 0,0066 | 0,0002 | 0,0025 | 0,2440 | 0,0096 | 0 |

Dari Tabel 4.19 dan Tabel 4.20 terlihat bahwa pada periode pertama pandemi telah terjadi kenaikan jumlah *tweet* ‘Negatif’ yang signifikan hampir pada semua penyedia layanan ($p\text{-value} \leq 0,05$). Terjadinya kenaikan jumlah layanan yang diberikan yang diindikasikan dengan meningkatnya jumlah *tweet*, tetapi juga diikuti dengan meningkatnya jumlah ketidakpuasan, terindikasi dari tren polaritas sentimen ‘Negatif’, menunjukkan bahwa sistem yang ada pada penyedia layanan saat ini tidak kuat atau tidak siap menghadapi

fluktuasi permintaan akan layanan. Dalam periode ini, JNT merupakan satu-satunya penyedia layanan yang terpengaruh oleh pandemi dimana adanya pandemi namun tidak signifikan yang ditunjukkan dengan nilai signifikansi $p\text{-value} = 0,0639$.

Selanjutnya, hasil uji korelasi dan signifikansi polaritas sentimen ‘Negatif’ dengan pandemi covid-19 untuk periode kedua pandemi dapat dilihat pada Tabel 4.21 dan Tabel 4.22 sesuai dengan data yang tercetak tebal.

Tabel 4.21. Uji korelasi *tweet* 'Negatif' vs periode kedua pandemi

| | cov/psbb | JNE | JNT | PosIndo | SiCepat | Tiki |
|----------|---------------|--------|---------|---------|---------|------|
| cov/psbb | 1 | | | | | |
| JNE | 0,8216 | 1 | | | | |
| JNT | 0,1826 | 0,4500 | 1 | | | |
| PosIndo | 0,8216 | 0,4333 | -0,2500 | 1 | | |
| SiCepat | 0,8216 | 0,8833 | 0,4333 | 0,4667 | 1 | |
| Tiki | 0,4564 | 0,7833 | 0,8000 | -0,0500 | 0,6833 | 1 |

Dari Tabel 4.21 dan Tabel 4.22 dapat diketahui bahwa pada periode kedua pandemi, terjadi sedikit perubahan korelasi antara jumlah *tweet* ‘Negatif’ dengan pandemi. Pada periode ini, JNT bukan lagi satu-satunya penyedia layanan yang masih terpengaruh namun tidak signifikan oleh pandemi tetapi juga ada Tiki yang sudah mengalami pemulihan, dimana korelasi tren sentimen ‘Negatif’ untuk penyedia layanan ini tidak lagi signifikan ($p\text{-value} = 0,2168$). Pemulihan mungkin saja lebih mudah dilakukan oleh Tiki karena jumlah permintaan pengiriman (*tweet*) penyedia layanan ini merupakan yang paling sedikit jika dibandingkan dengan penyedia layanan yang lain. Sedangkan *tweet* ‘Negatif’ penyedia layanan yang lain, pada periode ini masih terkoreksi secara signifikan dengan adanya pandemi ($p\text{-value} \leq 0,05$). JNT pada periode ini meski masih memiliki korelasi positif, namun korelasi tersebut sudah jauh tidak signifikan bila dibandingkan periode sebelumnya dengan $p\text{-value} = 0,6382$.

Tabel 4.22. Uji signifikansi korelasi *tweet* 'Negatif' vs periode kedua pandemi

| | cov/psbb | JNE | JNT | PosIndo | SiCepat | Tiki |
|----------|---------------|--------|--------|---------|---------|------|
| cov/psbb | 0 | | | | | |
| JNE | 0,0066 | 0 | | | | |
| JNT | 0,6382 | 0,2242 | 0 | | | |
| PosIndo | 0,0066 | 0,2440 | 0,5165 | 0 | | |
| SiCepat | 0,0066 | 0,0016 | 0,2440 | 0,2054 | 0 | |
| Tiki | 0,2168 | 0,0125 | 0,0096 | 0,8984 | 0,0424 | 0 |

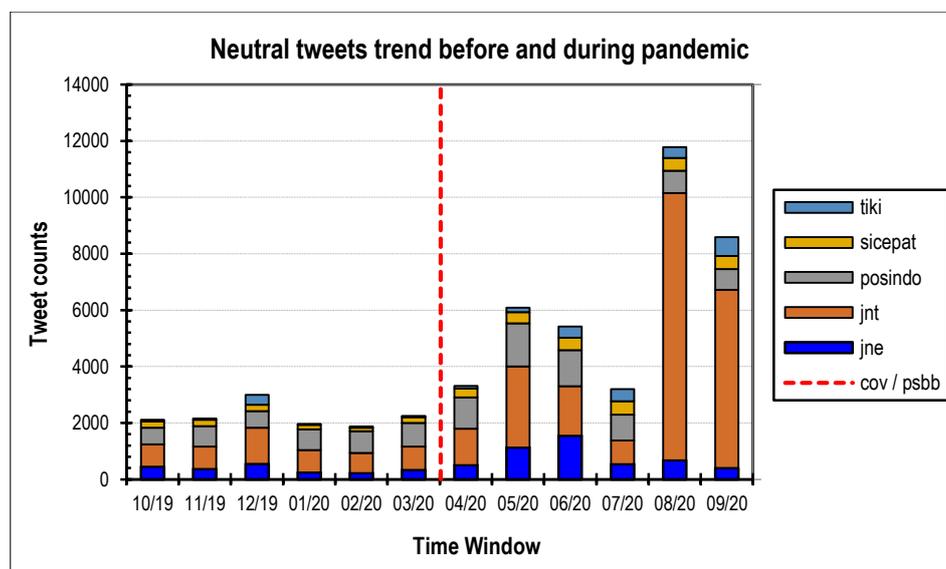
Hasil uji korelasi dan signifikansi pada periode kedua pandemi ini memberikan informasi bahwa telah terjadi proses perbaikan layanan yang diindikasikan dengan menurunnya jumlah *tweet* ‘Negatif’. Namun hal ini tidak terjadi pada semua penyedia layanan, tetapi hanya terjadi pada JNT dan Tiki, sedangkan pada penyedia layanan yang lain belum menunjukkan adanya perbaikan.

Kelompok 2 – data dengan polaritas sentimen ‘Netral’

Data dengan polaritas sentimen ‘Netral’ sebelum dan selama ditunjukkan oleh Tabel 4.23 dan disajikan secara grafis pada Gambar 4.15.

Tabel 4.23. *Tweet* 'Netral' sebelum dan selama pandemi

| Bulan | cov/psbb | JNE | JNT | PosIndo | SiCepat | Tiki |
|---------|----------|------|------|---------|---------|------|
| 2019-10 | 0 | 449 | 790 | 593 | 221 | 61 |
| 2019-11 | 0 | 366 | 798 | 723 | 227 | 39 |
| 2019-12 | 0 | 551 | 1283 | 584 | 228 | 354 |
| 2020-01 | 0 | 244 | 798 | 727 | 160 | 39 |
| 2020-02 | 0 | 221 | 716 | 771 | 117 | 45 |
| 2020-03 | 0 | 331 | 835 | 837 | 204 | 47 |
| 2020-04 | 1 | 507 | 1294 | 1106 | 314 | 95 |
| 2020-05 | 1 | 1128 | 2877 | 1522 | 395 | 163 |
| 2020-06 | 1 | 1552 | 1754 | 1274 | 443 | 399 |
| 2020-07 | 1 | 534 | 840 | 917 | 479 | 434 |
| 2020-08 | 1 | 675 | 9471 | 799 | 454 | 380 |
| 2020-09 | 1 | 404 | 6312 | 738 | 461 | 667 |



Gambar 4.15. *Tweet* 'Netral' sebelum dan selama pandemi

Data terklasifikasi ‘Netral’ adalah *tweet* yang tidak menunjukkan polaritas sentimen, seperti menanyakan seputar tarif, kerja sama, dan lain-lain. Dari Tabel 4.23 dan Gambar 4.15 secara sekilas terlihat bahwa terjadi sedikit kenaikan jumlah data pada periode pertama pandemi yang kemudian terjadi kenaikan jumlah data secara ekstrem pada periode kedua pandemi khususnya pada bulan Agustus dan September 2020. Adapun hasil uji korelasi dan signifikansi polaritas sentimen ‘Netral’ dengan pandemi covid-19 untuk periode pertama dapat dilihat pada Tabel 4.24 dan Tabel 4.25 sesuai dengan data yang tercetak tebal.

Tabel 4.24. Uji korelasi *tweet* 'Netral' vs periode pertama pandemi

| | cov/psbb | JNE | JNT | PosIndo | SiCepat | Tiki |
|----------|---------------|--------|--------|---------|---------|------|
| cov/psbb | 1 | | | | | |
| JNE | 0,7303 | 1 | | | | |
| JNT | 0,8250 | 0,8368 | 1 | | | |
| PosIndo | 0,8216 | 0,3500 | 0,6444 | 1 | | |
| SiCepat | 0,8216 | 0,9667 | 0,8787 | 0,4667 | 1 | |
| Tiki | 0,6417 | 0,8870 | 0,7311 | 0,3264 | 0,7950 | 1 |

Tabel 4.25. Uji signifikansi korelasi *tweet* 'Netral' vs periode pertama pandemi

| | cov/psbb | JNE | JNT | PosIndo | SiCepat | Tiki |
|----------|---------------|--------|--------|---------|---------|------|
| cov/psbb | 0 | | | | | |
| JNE | 0,0255 | 0 | | | | |
| JNT | 0,0062 | 0,0049 | 0 | | | |
| PosIndo | 0,0066 | 0,3558 | 0,0610 | 0 | | |
| SiCepat | 0,0066 | 0 | 0,0018 | 0,2054 | 0 | |
| Tiki | 0,0625 | 0,0014 | 0,0252 | 0,3914 | 0,0104 | 0 |

Data uji korelasi dan signifikansi tren *tweet* ‘Netral’ menunjukkan bahwa jumlah *tweet* ‘Netral’ pada periode pertama pandemi terjadi peningkatan yang signifikan hampir semua penyedia layanan, kecuali Tiki. Tren *tweet* ‘Netral’ untuk Tiki pada periode ini juga mengalami kenaikan, namun kenaikan tersebut tidak signifikan.

Tren sentimen ‘Netral’ periode kedua menunjukkan hasil uji korelasi dan signifikansi yang berbeda dibandingkan periode sebelumnya. Seperti yang dapat dilihat pada Tabel 4.26 dan Tabel 4.27, meskipun masih memiliki tren kenaikan jumlah pada seluruh penyedia layanan, signifikansi *tweet* ‘Netral’ cenderung fluktuatif. Pada periode ini, tren jumlah *tweet* ‘Netral’ untuk JNE dan Pos Indonesia tidak lagi signifikan, tren *tweet* ‘Netral’ Tiki berubah menjadi signifikan seperti halnya tren *tweet* ‘Netral’ untuk JNT dan SiCepat.

Tabel 4.26. Uji korelasi *tweet* 'Netral' vs periode kedua pandemi

| | cov/psbb | JNE | JNT | PosIndo | SiCepat | Tiki |
|----------|---------------|---------|--------|---------|---------|------|
| cov/psbb | 1 | | | | | |
| JNE | 0,5477 | 1 | | | | |
| JNT | 0,7334 | 0,7197 | 1 | | | |
| PosIndo | 0,5477 | -0,0667 | 0,2259 | 1 | | |
| SiCepat | 0,8216 | 0,7833 | 0,7782 | 0,2000 | 1 | |
| Tiki | 0,8250 | 0,6862 | 0,7311 | 0,2929 | 0,8285 | 1 |

Tabel 4.27. Uji signifikansi korelasi *tweet* 'Netral' vs periode kedua pandemi

| | cov/psbb | JNE | JNT | PosIndo | SiCepat | Tiki |
|----------|---------------|--------|--------|---------|---------|------|
| cov/psbb | 0 | | | | | |
| JNE | 0,1269 | 0 | | | | |
| JNT | 0,0245 | 0,0288 | 0 | | | |
| PosIndo | 0,1269 | 0,8647 | 0,5588 | 0 | | |
| SiCepat | 0,0066 | 0,0125 | 0,0135 | 0,6059 | 0 | |
| Tiki | 0,0062 | 0,0412 | 0,0252 | 0,4444 | 0,0058 | 0 |

Analisis lebih mendalam dilakukan terhadap konten *tweet* pada kelompok data ini, khususnya data bulan Agustus 2020 dan September 2020 dimana terjadi kenaikan jumlah data yang ekstrem. Dari analisis terhadap konten data tersebut didapati bahwa mayoritas *tweet* yang terklasifikasi 'Netral' khususnya pada bulan Agustus 2020 dan September 2020 ini merupakan *tweet* keikutsertaan pelanggan dalam promo-promo maupun acara terkait hari kemerdekaan Republik Indonesia dan ulang tahun salah satu penyedia layanan. Promo ini mengharuskan pelanggan menulis ucapan selamat ulang tahun yang unik pada masing-masing akun mereka. *Tweet-tweet* yang ditulis ini oleh model terklasifikasi ke dalam kelas sentimen "Netral" dan 'Positif'.

Contoh *tweet* pelanggan berkaitan dengan promo atau acara ulang tahun salah satu penyedia dapat dilihat pada Tabel 4.28.

Tabel 4.28. Konten *tweet* 'Netral' bulan Agustus - September 2020

| Indeks | Tweet Normalisasi |
|--------|--|
| 162974 | bismillahirrahmanirrahim semoga amp menjadi perusahaan ekspedisi nomor di indonesia shopeepay buat belanja bulanan |
| 162512 | jnt itu ada singkatan nya jasa pengiriman tercepat nomor ekspedisinya tuh kan saya menang giveaway |

| Indeks | Tweet Normalisasi |
|--------|--|
| 161945 | semoga dengan ikut di tweet ini bisa menang amin kalau misal dapat saldo shopeepay mau saya menggunakan buat beli kado mama saya karena sebentar lagi dia ulang tahun semoga bisa dapat amin ya allah |
| 168698 | semoga jnt semakin sukses selalu amanah dan berkah usahanya uang tunai juta akan sangat bermanfaat bisa meringankan beban orang tua |
| 166353 | beli kompor admin buat mama boleh ya |
| 170319 | saya tim pantang menyerah hampir semua ikutan tapi walaupun tidak pernah menang sih ya simple saja mungkin memang belum rejeki |
| 189079 | dear jnt walaupun akunku tidak se menarik para kurir dan tatanan kinerja pegawaimu tapi semoga komenkuh bisa menarik perhatianmu dan menarik hape realme profesional kedekapanku aamiin dear jnt ikan hiu makan bakso saya mau hape realme profesional |
| 184833 | dear jnt ikan hiu ke balikpapan jnt semakin terdepan sering sering memberikan gratis biaya kirim giveaway yahh wakakka |
| 172500 | malming enakny mendengarkan lagunya seventeen yang hug sama home soalnya malming enakny di rumah sambil di peluk loh |
| 180361 | paket ikan paus jago berenang yuk ikutan semoga kita menang |

Konten polaritas sentimen ‘Netral’ seperti yang terlihat pada contoh Tabel 4.28 ini merupakan *tweet* yang tidak menggambarkan polarisasi sentimen pelanggan sebenarnya. Polaritas sentimen ini mudah sekali terintervensi dengan adanya promosi-promosi atau acara tertentu yang diselenggarakan oleh penyedia layanan. Oleh sebab itu, kelompok data dengan polaritas sentimen ‘Netral’ pada penelitian tidak dapat dijadikan parameter yang objektif dalam melihat tren sentimen dan korelasinya terhadap suatu peristiwa dalam hal ini pandemi Covid-19 melalui analisis jendela waktu.

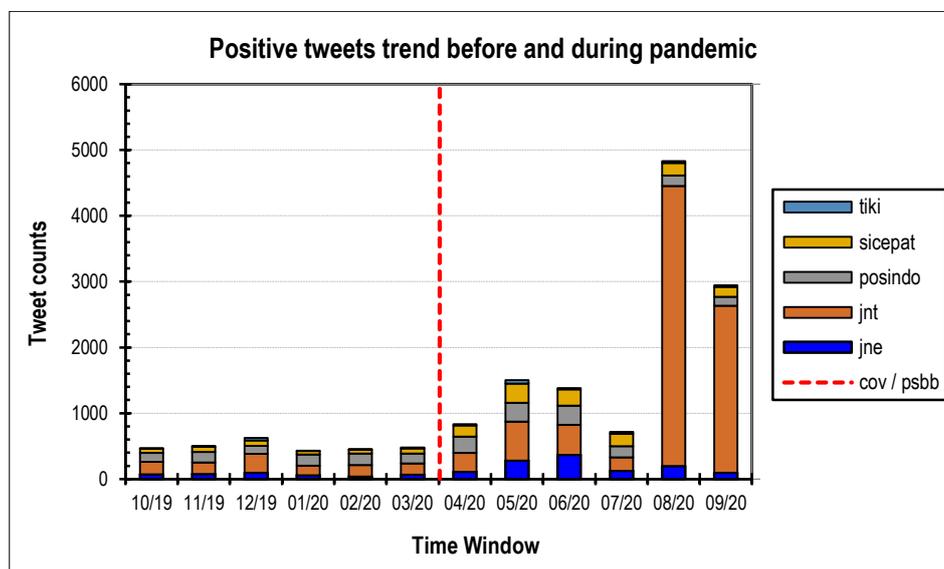
Kelompok 3 – data dengan polaritas sentimen ‘Positif’

Data dengan polaritas sentimen ‘Positif’ sebelum dan selama ditunjukkan oleh Tabel 4.29 dan disajikan secara grafis pada Gambar 4.16.

Tabel 4.29. *Tweet* 'Positif' sebelum dan selama pandemi

| Bulan | cov/psbb | JNE | JNT | PosIndo | SiCepat | Tiki |
|---------|----------|-----|------|---------|---------|------|
| 2019-10 | 0 | 73 | 190 | 135 | 62 | 12 |
| 2019-11 | 0 | 76 | 174 | 161 | 78 | 13 |
| 2019-12 | 0 | 98 | 286 | 121 | 82 | 39 |
| 2020-01 | 0 | 59 | 142 | 171 | 52 | 6 |
| 2020-02 | 0 | 40 | 173 | 176 | 59 | 6 |
| 2020-03 | 0 | 66 | 173 | 147 | 79 | 17 |
| 2020-04 | 1 | 112 | 286 | 245 | 171 | 18 |
| 2020-05 | 1 | 280 | 592 | 288 | 291 | 50 |
| 2020-06 | 1 | 370 | 455 | 290 | 246 | 23 |
| 2020-07 | 1 | 126 | 201 | 173 | 187 | 29 |
| 2020-08 | 1 | 196 | 4258 | 159 | 189 | 28 |

| Bulan | cov/psbb | JNE | JNT | PosIndo | SiCepat | Tiki |
|---------|----------|-----|------|---------|---------|------|
| 2020-09 | 1 | 96 | 2539 | 133 | 152 | 26 |



Gambar 4.16. *Tweet* 'Positif' sebelum dan selama pandemi

Data terklasifikasi 'Positif' adalah *tweet* yang menunjukkan polaritas sentimen 'Positif' terhadap layanan, seperti ungkapan apresiasi terhadap kinerja, kesesuaian layanan dengan estimasi yang diharapkan, dan lain-lain. Dari Tabel 4.29 dan Gambar 4.16 memiliki kemiripan dengan kelompok data dengan polaritas sentimen 'Positif' tersebut, dimana secara sekilas terlihat bahwa terjadi sedikit kenaikan jumlah data pada periode pertama pandemi yang kemudian terjadi kenaikan jumlah data secara ekstrem pada periode kedua, khususnya bulan Agustus dan September 2020.

Hasil uji korelasi dan signifikansi polaritas sentimen 'Positif' dengan pandemi covid-19 untuk periode pertama dapat dilihat pada Tabel 4.30 dan Tabel 4.31 sesuai dengan data yang tercetak tebal.

Tabel 4.30. Uji korelasi *tweet* 'Positif' vs periode pertama pandemi

| | cov/psbb | JNE | JNT | PosIndo | SiCepat | Tiki |
|----------|---------------|--------|--------|---------|---------|------|
| cov/psbb | 1 | | | | | |
| JNE | 0,8216 | 1 | | | | |
| JNT | 0,7825 | 0,9328 | 1 | | | |
| PosIndo | 0,8216 | 0,4667 | 0,4118 | 1 | | |
| SiCepat | 0,8216 | 0,9167 | 0,9076 | 0,4667 | 1 | |
| Tiki | 0,6417 | 0,8619 | 0,8734 | 0,2259 | 0,9456 | 1 |

Tabel 4.31. Uji signifikansi korelasi *tweet* 'Positif' vs periode pertama pandemi

| | cov/psbb | JNE | JNT | PosIndo | SiCepat | Tiki |
|----------|---------------|--------|--------|---------|---------|------|
| cov/psbb | 0 | | | | | |
| JNE | 0,0066 | 0 | | | | |
| JNT | 0,0127 | 0,0002 | 0 | | | |
| PosIndo | 0,0066 | 0,2054 | 0,2708 | 0 | | |
| SiCepat | 0,0066 | 0,0005 | 0,0007 | 0,2054 | 0 | |
| Tiki | 0,0625 | 0,0028 | 0,0021 | 0,5588 | 0,0001 | 0 |

Data uji korelasi dan signifikansi pandemi dengan tren *tweet* 'Positif' menunjukkan bahwa jumlah *tweet* 'Positif' pada periode pertama pandemi terjadi peningkatan yang signifikan hampir semua penyedia layanan, kecuali Tiki. Tren *tweet* 'Netral' Tiki pada periode ini juga mengalami kenaikan, namun kenaikan tersebut tidak signifikan. Hasil uji ini memiliki kemiripan dengan hasil yang didapatkan pada pengujian tren polaritas sentimen 'Netral'.

Tren sentimen 'Positif' periode tiga bulan kedua menunjukkan hasil uji korelasi dan signifikansi hampir sama jika dibandingkan periode sebelumnya. Seperti yang dapat dilihat pada Tabel 4.26 dan Tabel 4.27, perbedaan tren data tiga bulan pertama dan kedua pandemi terletak pada hasil uji korelasi dan signifikansi pandemi terhadap penyedia layanan Pos Indonesia. Pada periode ini tidak ada perbedaan jumlah *tweet* 'Positif' yang berarti untuk penyedia layanan Pos Indonesia yang diindikasikan dengan nilai korelasi = 0 dan uji signifikansi = 1.

Tabel 4.32. Uji korelasi *tweet* 'Positif' vs periode kedua pandemi

| | cov/psbb | JNE | JNT | PosIndo | SiCepat | Tiki |
|----------|---------------|---------|---------|---------|---------|------|
| cov/psbb | 1 | | | | | |
| JNE | 0,7303 | 1 | | | | |
| JNT | 0,7334 | 0,8870 | 1 | | | |
| PosIndo | 0 | -0,3333 | -0,5105 | 1 | | |
| SiCepat | 0,8216 | 0,9167 | 0,8619 | -0,3000 | 1 | |
| Tiki | 0,5500 | 0,8787 | 0,7689 | -0,4686 | 0,8787 | 1 |

Tabel 4.33. Uji signifikansi korelasi *tweet* 'Positif' vs periode kedua pandemi

| | cov/psbb | JNE | JNT | PosIndo | SiCepat | Tiki |
|----------|---------------|--------|--------|---------|---------|------|
| cov/psbb | 0 | | | | | |
| JNE | 0,0255 | 0 | | | | |
| JNT | 0,0245 | 0,0014 | 0 | | | |
| PosIndo | 1 | 0,3807 | 0,1603 | 0 | | |

| | | | | | | |
|---------|---------------|--------|--------|---------|---------|------|
| | cov/psbb | JNE | JNT | PosIndo | SiCepat | Tiki |
| SiCepat | 0,0066 | 0,0005 | 0,0028 | 0,4328 | 0 | |
| Tiki | 0,1250 | 0,0018 | 0,0155 | 0,2032 | 0,0018 | 0 |

Seperti halnya dengan kelompok data *tweet* ‘Netral’, hasil analisis konten pada *tweet* yang terklasifikasi ‘Positif’, khususnya bulan Agustus 2020 dan September 2020 merupakan *tweet* keikutsertaan pelanggan dalam promo-promo maupun acara terkait hari kemerdekaan Republik Indonesia dan ulang tahun salah satu penyedia layanan.

Contoh *tweet* pelanggan berkaitan dengan promo atau acara ulang tahun salah satu penyedia yang terklasifikasi memiliki polaritas sentimen ‘Positif’ dapat dilihat pada Tabel 4.34.

Tabel 4.34. Konten *tweet* 'Positif' bulan Agustus - September 2020

| Indeks | Tweet Normalisasi |
|--------|--|
| 168207 | wish nya semoga menjadi jasa pengiriman yang paling terdepan paling terpercaya dan terima kasih sudah hadir karena kamulah pavorit ku |
| 163036 | selamat ulang tahun jnt semoga menjadi lebih baik lagi kedepannya dan semakin mantap semoga saya dapat hp nya untuk belajar |
| 163297 | selamat ulang tahun yang ke tahun sukses jaya selalu bismillah semoga rejeki |
| 160193 | di ulang tahun ke amp semoga kedepannya bisa menjadi lebih baik dan bisa menjadi jasa pengiriman terbaik di indonesia |
| 162544 | happy ulang tahun amp semoga selalu jadi ekspedisi terdepan saya sll pilih amp baik untuk kirim barang maupun saat belanja di commerce |
| 170830 | girlband favorite saya ya selain lagunya baguss mereka sayangg banget sama para fansnya once mereka juga ramah baik sama fandom lain lagu favoritku dari twice banyak bgett paling favorit sekarang ini ya more amp more |
| 190399 | semakin banyak yang retweet artinya semakin banyak yang miskin mengharap oppo dari xiami goks banget |
| 161230 | jnt semoga dapat hadiah dari jnt |
| 165934 | selamat ulang tahun semoga makin maju amp berkembang sampai ke pelosok negeri dan tambah luas go international nya amin |
| 169807 | semoga saya dapat giveaway dari jnt uangnya saya mau belanjakan di shopee terus kirimnya tetap pakai jnt andalanku |

Sama halnya dengan *tweet* dengan polaritas sentimen ‘Netral’, *tweet* dengan polaritas sentimen ‘Positif’ tidak dapat dijadikan parameter yang objektif dalam melihat tren sentimen dan korelasinya terhadap pandemi Covid-19 karena polaritas sentimen ini mudah sekali terintervensi dengan adanya promosi-promosi atau acara tertentu yang diselenggarakan oleh penyedia layanan.

4.6 Pemodelan Topik

Selain memperoleh tren sentimen dan korelasinya terhadap pandemi covid-19, penelitian ini juga memiliki tujuan mengekstraksi topik dari sentimen yang berpengaruh dan memiliki korelasi terhadap pandemi tersebut. Mengingat hanya polaritas sentimen ‘Negatif’ yang dapat dipergunakan sebagai parameter objektif, maka tahap pemodelan topik hanya dilakukan terhadap kelas sentimen ini.

Sama halnya dalam pembuatan model klasifikasi, dimana tahap pemodelan topik tidak mengikutsertakan data berdimensi sangat rendah (≤ 2 kata) dan data berdimensi sangat tinggi (> 16 kata) yang masuk dalam *outlier* berdasarkan distribusi normal. Adapun jumlah data terklasifikasi ‘Negatif’ yang dipergunakan secara keseluruhan berjumlah 92.202 data, dimana data tersebut kemudian dibagi dalam 3 (tiga) *sub-set*, yaitu data sebelum pandemi = 33.447 data, data periode pertama pandemi = 35.814 data, dan data periode kedua pandemi = 22.941 data. Pembagian *sub-set* data ini sama dengan pembagian *sub-set* data pada analisis sentimen jendela waktu untuk polaritas sentimen ‘Negatif’.

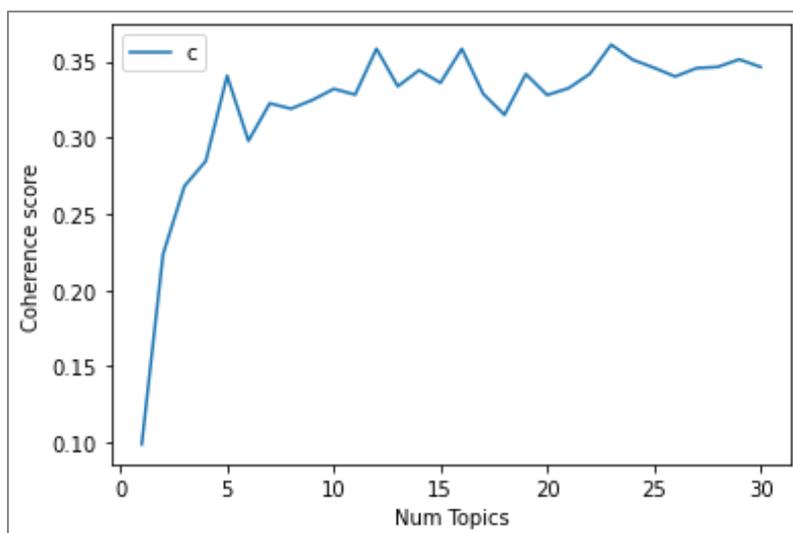
Seperti telah disebutkan pada bab sebelumnya, pemodelan topik dalam penelitian ini menggunakan pendekatan LDA-Mallet dengan terlebih dahulu mempersiapkan n-gram kata (hingga 3 kata), yaitu menggabungkan kata yang secara konsisten muncul bersamaan menjadi satu dengan menambahkan tanda hubung ‘_’ untuk mendapatkan hasil ekstraksi topik yang lebih baik. Contoh kata yang sering muncul dalam data antara lain: kata ‘layan’ dan ‘langgan’ digabung menjadi ‘layan_langgan’, kata ‘status’ dan ‘delivered’ menjadi ‘status_delivered’, kata ‘follow’ dan ‘up’ menjadi ‘follow_up’, dan seterusnya.

Kata yang dipergunakan untuk keseluruhan proses pemodelan topik (sebelum, tiga bulan pertama, dan tiga bulan kedua pandemi) adalah kata yang muncul lebih dari 50 kali tetapi tidak terdapat di lebih dari 50% kalimat dalam data masing-masing *sub-set*. Pertimbangannya adalah kata yang muncul kurang dari 50 dianggap belum mewakili konten dokumen, sedangkan kata yang muncul lebih dari 50% data berpotensi merupakan kata *stopword* yang masih ikut serta.

4.6.1 Topik *tweet* “Negatif” sebelum pandemi

Langkah pertama dalam proses pemodelan topik dengan pendekatan LDA atau LDA-Mallet adalah menentukan jumlah topik yang ingin diekstraksi. Pendekatan terbaik dalam

menentukan jumlah topik adalah dengan menghitung skor *coherence*, dimana semakin tinggi nilainya, semakin baik ekstraksi topik yang didapatkan. Perhitungan skor *coherence* untuk masing-masing jumlah topik untuk *sub-set* data sebelum pandemi dapat dilihat pada Gambar 4.17.



Gambar 4.17. *Coherence score* n-topik sentimen 'Negatif' sebelum pandemi

Gambar 4.17 menyajikan informasi bahwa skor *coherence* yang didapatkan dalam ekstraksi topik berkisar antara 0,3-0,35. Nilai tersebut dapat dikatakan cukup rendah, dimana hal ini kemungkinan disebabkan karena besarnya jumlah data yang dipergunakan. Namun demikian penentuan jumlah topik terbaik dari pilihan yang tersedia dapat ditentukan dengan metode *elbow* (mirip penentuan jumlah faktor pada faktor analisis). Perubahan skor *coherence* signifikan terjadi hingga jumlah topik ke-5 (skor *coherence* = 0,3406) dan melandai setelahnya, sehingga pada *sub-set* ini ekstraksi 5 topik menjadi pilihan yang paling optimal. 5 topik yang berhasil terekstrak dapat dilihat dari data ini ditunjukkan oleh Tabel 4.35.

Tabel 4.35. Topik *tweet* 'Negatif' sebelum pandemi

| Topik Ke | Kata Kunci | | Tweet Representatif | Topik Laten |
|----------|------------------|---|--|-------------------------------|
| 1 | 0.067*"pakai" | + | paket saya kok lama benar admin sampainya beberapakali pakai jnt aga mengecewakan datangnya suka telat tapi kali ini telatnya parah pakai jnt soalnya tidak ada pilihan lain | kecepatan dan jaminan layanan |
| | 0.045*"layan" | + | | |
| | 0.041*"komplain" | + | | |
| | 0.040*"kali" | + | | |
| | 0.033*"cepat" | + | | |

| Topik Ke | Kata Kunci | Tweet Representatif | Topik Laten |
|----------|--|---|--------------------------------------|
| | 0.033*"respons" + 0.025*"lambat" + 0.025*"hilang" + 0.025*"kecewa" | kalau ada yang lain saya lebih memilih pesaing anda sorry saya banding kan tetapi ini supaya jnt memperbaiki kinerjanya | |
| 2 | 0.125*"periksa" + 0.100*"status" + 0.068*"lacak" + 0.060*"bantu" + 0.050*"informasi" + 0.047*"follow_up" + 0.045*"ubah" + 0.044*"gerak" + 0.036*"update" + 0.034*"taju" | selamat siang pos indonesia saya kirum barang ke india lewat ems pos indonesia dari tanggal sampai sekarang status di website pelacakan masih tertahan di customs status pelacakan belum update deh dari tanggal mohon informasinya pak | pelacakan dan pembaharuan informasi |
| 3 | 0.037*"tahan" + 0.034*"gudang" + 0.033*"proses" + 0.031*"pagi" + 0.027*"jalan" + 0.027*"henti" + 0.024*"tunggu" + 0.024*"malam" + 0.023*"minggu" | woi mohon lah layanan pelanggan nya tuh mana sih ini perusahaan punya layanan layanan pelanggan tidak sih jp masa hari sesama kota itu barang berhenti digudang setidaknya kalau ada kendala yang speak up lah | progres pengiriman |
| 4 | 0.356*"terima" + 0.116*"kasih" + 0.081*"status" + 0.065*"rumah" + 0.052*"bantu" + 0.048*"pesan" + 0.038*"periksa" + 0.031*"nama" + 0.027*"shope" + 0.026*"terang" | selamat sore kak tadi pesanan saya dari shopee sudah ditulis kalau diterima oleh saya tapi sendiri belum menerima paket saya dan ketika saya tanyakan ke keluarga juga belum ada yang menerima paket dari saya bagaimana ya kak mohon bantuannya terima kasih | sinkronisasi informasi status barang |
| 5 | 0.107*"kurir" + 0.069*"alamat" + 0.052*"telepon" + 0.037*"salah" + 0.033*"ambil" + 0.031*"beli" + 0.026*"hubung" + 0.025*"konfirmasi" + 0.025*"bilang" + 0.024*"langsung" | beginikah jawaban tokopedia mengenai hal ini sicepat suka merubah berat tanpa infokan ke seller tapi kenapa tokopedia main asal memotong dana seller padahal di halaman tokopedia sudah jelas kurir harusnya dikonfirmasi dulu | konfirmasi pengiriman |

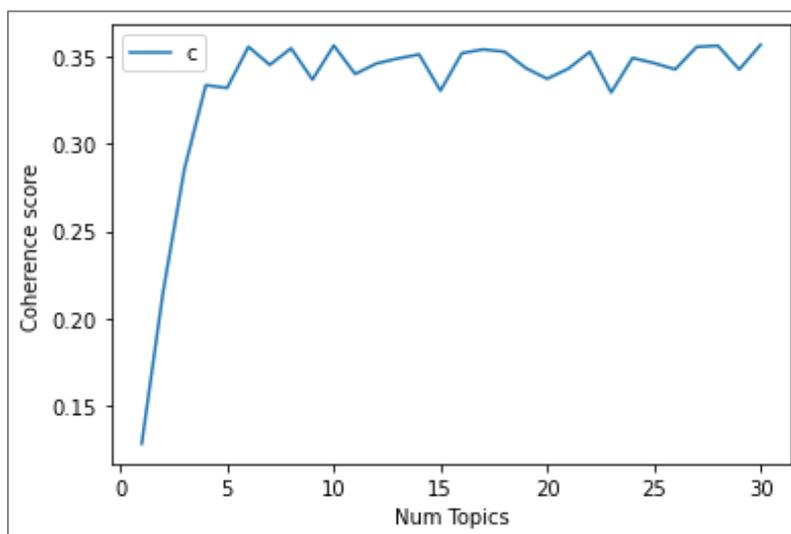
Tabel 4.28 memberikan 5 topik sentimen ‘Negatif’ sebelum masa pandemi, yaitu:

- Kecepatan dan jaminan layanan
Topik ini berisikan *tweet-tweet* yang menyampaikan keluhan tentang lambatnya proses pengiriman dan mempertanyakan bentuk tanggung jawab penyedia layanan terhadap kerusakan (penyok, terpotong, terlipat) dan kehilangan barang.
- Pelacakan dan pembaharuan informasi
Topik ini berisikan *tweet-tweet* yang menyampaikan permintaan pelacakan barang dan pembaharuan informasi terhadap status barang yang sedang dikirimkan. Mayoritas permintaan ini dilakukan karena informasi yang ada dalam aplikasi *ecommerce* tidak mengalami perubahan setelah beberapa waktu (hari).
- Progres pengiriman
Topik ini berisikan *tweet-tweet* yang menyampaikan permintaan penanganan mengenai kondisi status barang yang sedang dikirimkan. Berbeda dengan topik ‘pelacakan dan pembaharuan informasi’, topik ini memuat permintaan konsumen untuk segera melakukan tindakan terkait kendala pengiriman yang dihadapi berdasarkan informasi yang telah diterima pengguna layanan.
- Sinkronisasi informasi status barang
Topik ini berisikan *tweet-tweet* yang menyampaikan keluhan mengenai perbedaan status barang pada aplikasi *ecommerce* maupun sistem pelacakan dengan kondisi riil yang terjadi pada pelanggan.
- Konfirmasi pengiriman
Topik ini berisikan *tweet-tweet* yang menyampaikan permintaan konfirmasi dan keterlibatan pelanggan terkait hal-hal yang tidak standar dalam proses pengiriman sebelum pihak penyedia layanan (kurir) menentukan suatu tindakan.

4.6.2 Topik *tweet* ‘Negatif’ periode pertama pandemi

Penentuan jumlah topik optimal pada periode ini ditunjukkan oleh Gambar 4.18, dimana gambar ini memberikan hasil perhitungan skor *coherence* untuk ekstraksi hingga 30 topik untuk *sub-set* kedua dalam pemodelan topik ini. Skor *coherence* yang mampu didapatkan dalam ekstraksi topik berdasarkan grafik ini menunjukkan nilai 0,30-0,40. Perubahan skor signifikan terjadi hingga jumlah topik ke-6 (skor *coherence* = 0,3556) dan melandai

setelahnya, sehingga pada *sub-set* ini ekstraksi 6 topik menjadi pilihan yang paling optimal.



Gambar 4.18. *Coherence score* n-topik sentimen 'Negatif' periode pertama pandemi

Adapun topik-topik yang dibentuk berdasarkan ekstraksi kata kunci dan *tweet-tweet* yang paling representatif dengan topik masing-masing pada periode ini dapat dilihat pada Tabel 4.36.

Tabel 4.36. Topik *tweet* 'Negatif' periode pertama pandemi

| Topik Ke | Kata Kunci | | Tweet Representatif | Topik Laten |
|----------|------------------|---|---|--------------------|
| 1 | 0.094*"dm" | + | sepertinya iya hanya buat terlihat modern untuk pembagian respons twit saja sudah terlihat mereka mengerti twit saya hari yang lalu nomor respons sedangkan twit orang lain hari ini di respons harus belajar sistem antrean dulu ini | layanan pelanggan |
| | 0.061*"respons" | + | | |
| | 0.052*"balas" | + | | |
| | 0.038*"cepat" | + | | |
| | 0.028*"tunggu" | + | | |
| | 0.026*"woi" | + | | |
| | 0.026*"customer" | + | | |
| | 0.022*"kabar" | + | | |
| | 0.020*"melulu" | + | | |
| 2 | 0.062*"telepon" | + | tolol semua memang pegawai nya masa saya sudah bayar biaya kirim suruh mengambil sendiri dengan alasan paket nya kegedean padahal cuma sepatu doang kalau malas tidak usah kerja bilang ke pegawai kamu | Pengantaran barang |
| | 0.044*"gudang" | + | | |
| | 0.032*"hubung" | + | | |
| | 0.030*"ambil" | + | | |
| | 0.029*"parah" | + | | |
| | 0.027*"bilang" | + | | |
| | 0.023*"kerja" | + | | |
| | 0.023*"pas" | + | | |
| | 0.022*"coba" | + | | |

| Topik Ke | Kata Kunci | | Tweet Representatif | Topik Laten |
|----------|---|---|--|-------------------------------------|
| 3 | 0.228*"terima" 0.083*"kurir" 0.074*"alamat" 0.067*"rumah" 0.044*"pesan" 0.038*"salah" 0.031*"shope" 0.031*"status" 0.027*"konfirmasi" 0.026*"terang" | + | kemarin status di shopee paket sudah diterima atas nama saya sendiri padahal saya belum terima hari ini ada orang telpon saya katanya ada paket atas nama saya dirumahnya tidak ada konfirmasi dari kurir yang antar main drop saja di rumah orang padahal alamat lengkap nomor hape ada | konfirmasi pengiriman |
| 4 | 0.091*"pakai" 0.051*"layan" 0.049*"kali" 0.049*"komplain" 0.032*"hilang" 0.030*"lambat" 0.028*"kecewa" 0.025*"maaf" 0.024*"ekspedisi" 0.024*"tanggung" | + | barang hilang di ekspedisi dan hanya diganti biaya kirim jika mau full harus pakai asuransi yang artinya meminta biaya lebih lucu ya itu tanggung jawabmu sebagai ekspedisi kenapa harus meminta biaya lebih untuk sesuatu yang dimana memang tgg jawabmu | kecepatan dan jaminan layanan |
| 5 | 0.157*"periksa" 0.135*"status" 0.127*"bantu" 0.115*"terima_kasih" 0.065*"lacak" 0.056*"informasi" 0.048*"follow_up" 0.044*"ubah" 0.039*"update" 0.020*"posisi" | + | mau menanyakan perihal status paket dengan awb rjua update lewat website sudah release per tanggal maret tapi sampai sekarang tidak ada update lagi apakah bisa dibantu updatenya terima kasih | pelacakan dan pembaharuan informasi |
| 6 | 0.086*"gerak" 0.073*"henti" 0.056*"tahan" 0.046*"tuju" 0.041*"periksa" 0.039*"minggu" 0.038*"jalan" 0.037*"proses" 0.037*"bandung" 0.026*"kota" | + | admin tolong paket saya takutnya mau tersesat lagi ini ke jambi tujuan harusnya ke padang sumatera barat tolong di periksa karena saya punya pengalaman buruk sebelumnya paket saya tersesat ke bireuen aceh dari tanggal sampai sekarang tidak ada kabar dan tidak sampai | progres pengiriman |

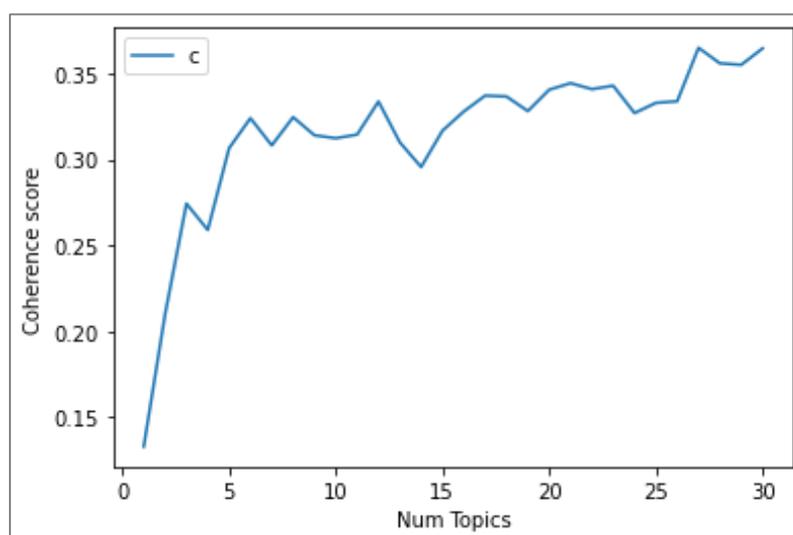
Tabel 4.36 memberikan 6 topik sentimen ‘Negatif’ periode pertama masa pandemi sesuai dengan skor *coherence* optimal yang mampu diberikan oleh model, yaitu:

- Layanan pelanggan
Topik ini berisikan *tweet-tweet* yang menyampaikan keluhan tentang lambatnya respons atau pesan balasan yang dilakukan pusat layanan pelanggan. Topik ini merupakan topik baru yang tidak muncul pada periode sebelumnya.
- Pengantaran barang
Topik ini berisikan *tweet-tweet* yang menyampaikan keluhan spesifik tentang masalah yang dihadapi terkait proses pengiriman dari gudang ke pelanggan. Bahkan beberapa *tweet* representatif menyatakan bahwa pelanggan diminta melakukan pengambilan sendiri barangnya digudang penyimpanan penyedia layanan. Topik ini juga merupakan topik baru yang tidak muncul pada periode sebelumnya.
- Konfirmasi pengiriman
Topik ini berisikan *tweet-tweet* yang menyampaikan permintaan konfirmasi dan keterlibatan pelanggan terkait hal-hal yang tidak standar dalam proses pengiriman sebelum pihak penyedia layanan (kurir) menentukan suatu tindakan. Topik ini merupakan topik yang juga muncul pada periode sebelumnya. Meskipun memiliki kata kunci yang sedikit berbeda dari periode sebelumnya, topik ini memiliki *tweet-tweet* representatif yang mirip.
- Kecepatan dan jaminan layanan
Topik ini berisikan *tweet-tweet* yang menyampaikan keluhan tentang lambatnya proses pengiriman secara umum dan mempertanyakan bentuk tanggung jawab penyedia layanan terhadap kerusakan (penyok, terpotong, terlipat) hingga kehilangan barang. Topik ini merupakan topik yang juga muncul pada periode sebelumnya. Meskipun memiliki kata kunci yang sedikit berbeda dari periode sebelumnya, topik ini memiliki *tweet-tweet* representatif yang mirip.
- Pelacakan dan pembaharuan informasi
Topik ini berisikan *tweet-tweet* yang menyampaikan permintaan pelacakan barang dan pembaharuan informasi terhadap status barang yang sedang dikirimkan. Mayoritas permintaan ini dilakukan karena informasi yang ada pada fasilitas pelacakan tidak mengalami perubahan setelah beberapa waktu (hari). Topik ini merupakan topik yang juga muncul pada periode sebelumnya.
- Progres pengiriman

Topik ini berisikan *tweet-tweet* yang menyampaikan permintaan penanganan mengenai kondisi status barang yang sedang dikirimkan. Berbeda dengan topik ‘pelacakan dan pembaharuan informasi’, topik ini memuat permintaan konsumen untuk segera melakukan tindakan terkait kendala pengiriman yang dihadapi berdasarkan informasi yang telah diterima pengguna layanan melalui fasilitas pelacakan pengiriman. Topik ini merupakan topik yang juga muncul pada periode sebelumnya. Meskipun memiliki kata kunci yang sedikit berbeda dari periode sebelumnya, topik ini memiliki *tweet-tweet* representatif yang mirip.

4.6.3 Topik *tweet* ‘Negatif’ periode kedua pandemi

Penentuan jumlah topik optimal pada periode ini ditunjukkan oleh Gambar 4.19. Skor *coherence* yang mampu didapatkan dalam ekstraksi topik berdasarkan grafik pada periode ini berkisar 0,30-0,40. Perubahan skor signifikan terjadi hingga jumlah topik ke-6 (skor *coherence* = 0,3363) dan melandai setelahnya, sehingga pada sub-set ini ekstraksi 6 topik menjadi pilihan yang paling optimal.



Gambar 4.19. *Coherence score* n-topik sentimen 'Negatif' periode kedua pandemi

Topik-topik yang berhasil dibentuk berdasarkan ekstraksi kata kunci dan *tweet-tweet* paling representatif dengan topik masing-masing pada periode kedua masa pandemi ini dapat dilihat pada Tabel 4.37.

Tabel 4.37. Topik *tweet* 'Negatif' periode kedua pandemi

| Topik Ke | Kata Kunci | | Tweet Representatif | Topik Laten |
|----------|--|---|---|--------------------------------------|
| 1 | 0.121*"periksa" 0.088*"alamat" 0.047*"taju" 0.043*"lacak" 0.035*"proses" 0.033*"terima_kasih" 0.033*"minggu" 0.031*"kota" 0.029*"maaf" 0.028*"coba" | + | halo mau tanya dong saya kirim paket jo di alamat saya tulis ke kabupaten siantang tapi kenapa waktu di track tujuannya ke kabupaten malawi ya | pelacakan barang |
| 2 | 0.164*"kurir" 0.090*"rumah" 0.056*"telepon" 0.042*"bilang" 0.038*"ambil" 0.038*"tunggu" 0.033*"hubung" 0.033*"pas" 0.030*"langsung" | + | admin kurirnya naro saja di kursi teras rumah orang padahal belum pastiin itu rumah saya apa bukan tidak menelpon baru percakapan sore setelah saya report ke layanan pelanggan amp ini percakapan nya akhirnya dia kembali lagi ke rumah yang salah terus mengantarkan ke saya | konfirmasi pengiriman |
| 3 | 0.274*"terima" 0.161*"status" 0.057*"pesan" 0.049*"shope" 0.039*"nama" 0.035*"periksa" 0.034*"konfirmasi" 0.033*"terang" 0.032*"tulisi" 0.021*"lapor" | + | paket belum datang kok sudah dikonfirmasi diterima dan terkirim penerimanya nama kurirnya sendiri kan harusnya barang kalau belum diterima jangan konfirmasi dan nama penerima barang ya orang yang menerima bukan nama kurir | sinkronisasi informasi status barang |
| 4 | 0.145*"pakai" 0.071*"kali" 0.045*"cepat" 0.035*"ekspedisi" 0.029*"kecewa" 0.027*"pilih" 0.026*"lihat" 0.022*"bikin" | + | admin benaran kamu namanya sicepat ganti nama saja deh cuma di ekspedisi ini paket saya tidak sampai padahal isinya tanaman salah pilih ekspedisi saya kecewa banget kapok banget keduluan sama paket lain yang kirimnya belakangan beda jauh malah | kecepatan pengiriman |
| 5 | 0.053*"layan" 0.052*"komplain" 0.049*"hilang" 0.043*"respons" 0.040*"tahan" 0.038*"dm" | + | meminta di dm tapi jawaban dm template banget kalau kirim paket harus jujur isinya apaan karena kalau rusak hilang mereka mau tanggung jawab tapi kalau jujur isinya apaan kemungkinan itu | jaminan layanan |

| Topik Ke | Kata Kunci | Tweet Representatif | Topik Laten |
|----------|--|---|--------------------------|
| | 0.035*"kerja" 0.029*"customer" 0.029*"tanggung" 0.027*"melulu" | + + + + paket tidak sampai besar sekali saya pernah mengalami ketawa | |
| 6 | 0.111*"bantu" 0.100*"terima_kasih" 0.076*"gerak" 0.062*"informasi" 0.053*"henti" 0.053*"update" 0.040*"pagi" 0.034*"follow_up" 0.031*"bandung" | + + + + + + + + + malam mohon informasi kenapa status barang saya dari denpasar ke surabaya dari tanggal september tidak berubah tetap di paket keluar dari denpasar line haul denpasar thx | pembaharuan informasi |

Tabel 4.37 menyajikan 6 topik sentimen ‘Negatif’ untuk periode kedua masa pandemi sesuai dengan skor *coherence* optimal yang mampu diberikan oleh model, yaitu:

- Pelacakan barang
Topik ini berisikan *tweet-tweet* yang menyampaikan permintaan pemeriksaan proses pengiriman dikarenakan sistem pelacakan memberikan informasi yang mengindikasikan kesalahan tujuan pengiriman. Dilihat dari kata kunci dan *tweet-tweet* representatifnya, topik ini bukan merupakan topik baru, melainkan topik spesifik dari topik yang muncul pada periode-periode sebelumnya yaitu topik ‘pelacakan dan pembaharuan informasi’.
- Konfirmasi pengiriman
Topik ini berisikan *tweet-tweet* yang menyampaikan permintaan konfirmasi dan keterlibatan pelanggan terkait hal-hal yang tidak standar dalam proses pengiriman sebelum pihak penyedia layanan (kurir) mengambil suatu tindakan. Topik ini merupakan topik yang juga muncul pada periode-periode sebelumnya. Meskipun memiliki kata kunci yang sedikit berbeda, topik ini memiliki *tweet-tweet* representatif yang mirip seperti dijumpai pada periode-periode sebelumnya.
- Sinkronisasi informasi status barang
Topik ini berisikan *tweet-tweet* yang menyampaikan keluhan mengenai perbedaan status barang (pada fasilitas pelacakan) dengan kondisi riil yang dihadapi pelanggan. Topik ini muncul pada periode sebelum pandemi, tidak muncul pada periode pertama pandemi, tetapi muncul kembali pada periode kedua pandemi ini.

- Kecepatan pengiriman
Topik ini berisikan *tweet-tweet* yang menyampaikan keluhan dan kekecewaan terhadap proses pengiriman yang tidak sesuai seperti yang dijanjikan. Topik ini bukan merupakan topik baru, melainkan topik spesifik dari topik yang muncul pada periode-periode sebelumnya yaitu topik ‘kecepatan dan jaminan layanan’.
- Jaminan pengiriman
Topik ini berisikan *tweet-tweet* yang mempertanyakan bentuk tanggung jawab penyedia layanan terhadap terjadinya kerusakan (penyok, terpotong, terlipat, dll) dan kehilangan barang. Topik ini juga bukan merupakan topik baru, melainkan topik spesifik dari topik yang muncul pada periode-periode sebelumnya yaitu topik ‘kecepatan dan jaminan layanan’.
- Pembaharuan informasi
Topik ini berisikan *tweet-tweet* yang menyampaikan permintaan pembaharuan informasi terhadap status barang yang sedang dikirimkan. Mayoritas permintaan ini dilakukan karena informasi yang ada dalam aplikasi *ecommerce* tidak mengalami perubahan setelah beberapa waktu (hari). Topik ini bukan merupakan topik baru, melainkan topik spesifik dari topik yang muncul pada periode-periode sebelumnya yaitu topik ‘pelacakan dan pembaharuan informasi’.

Dilihat dari 6 yang terbentuk pada periode kedua pandemi ini, sejatinya hanya memberikan hasil ekstraksi 4 topik utama yang sudah ada pada periode-periode sebelumnya, antara lain: (1) pelacakan dan pembaharuan informasi, (2) konfirmasi pengiriman, (3) sinkronisasi informasi status barang, dan (4) kecepatan dan jaminan pengiriman.

BAB 5

PENUTUP

5.1 Kesimpulan

Berdasarkan informasi yang tersedia, lokasi *tweet* menunjukkan sebaran hampir di seluruh wilayah Indonesia, akan tetapi mayoritas *tweet* ini masih didominasi oleh *tweet* yang berasal dari bagian barat pulau Jawa seperti daerah DKI Jakarta, Tangerang dan Banten, Jawa Barat, sebagian Jawa Tengah dan pulau Sumatera bagian selatan seperti Lampung dan Sumatera Selatan.

Penyedia layanan memberikan performa keaktifan pusat layanan yang berbeda dimana Pos Indonesia merupakan penyedia jasa layanan paling aktif dengan persentase 97,23% dari jumlah *tweet* yang disampaikan pelanggan. Hal ini dapat diartikan bahwa pusat layanan Pos Indonesia merespons hampir semua *tweet* yang ditujukan pada institusinya. Selanjutnya, keaktifan pusat layanan pelanggan disusul oleh Tiki 50,15%, JNE 20,73%, J&T 9,72%, dan di urutan terakhir SiCepat dengan hanya 5,00% dari keseluruhan *tweet* yang ditujukan padanya.

Jumlah *tweet* yang ditulis sebelum dan selama pandemi memiliki perbedaan yang signifikan, dimana terjadi kenaikan jumlah *tweet* selama pandemi. Kenaikan jumlah *tweet* tersebut mengindikasikan bahwa memang telah terjadi kenaikan jumlah layanan/pengiriman barang yang dilakukan selama pandemi ini. Jika diakumulasikan, jumlah *tweet* enam bulan sebelum pandemi adalah 61.889 (32,07%), sedangkan jumlah *tweet* untuk rentang waktu yang sama selama pandemi adalah 131.067 (67,93) atau mencapai lebih dari 200% dibandingkan periode sebelum pandemi.

Hasil analisis sentimen dan pemodelan topik berdasarkan jendela waktu yang telah dilakukan terhadap data percakapan Twitter sebelum dan selama pandemi, dapat diambil beberapa kesimpulan, antara lain:

5.1.1 Analisis Sentimen

Model klasifikasi yang telah berhasil dibuat memiliki akurasi yang sangat baik yaitu 89,21%. Dengan model ini klasifikasi keseluruhan data terkait pelayanan jasa pengiriman barang domestik di Indonesia memiliki hasil polaritas sentimen ‘Negatif’ = 65,32%, ‘Netral’ = 26,87%, dan ‘Positif’ = 7,87%. Analisis lebih lanjut menggunakan pendekatan

jendela waktu hanya dilakukan pada polaritas sentimen ‘Negatif’, dimana sentimen ‘Negatif’-lah yang mengindikasikan ketidakpuasan pelanggan atas layanan yang diberikan. Pertimbangan lainnya adalah polaritas sentimen yang lain tidak dapat dijadikan parameter sentimen yang objektif karena mudah terintervensi dengan adanya *event*, promo, maupun acara-acara lain yang diselenggarakan oleh pihak penyedia.

Terlepas dari adanya *tweet-tweet* promo dan *event* yang dapat menambah proporsi *tweet* ‘Netral’ dan ‘Positif’ menjadi lebih tinggi dari yang seharusnya, hasil analisis sentimen terhadap layanan pengiriman masih memberikan proporsi sentimen ‘Negatif’ yang lebih tinggi dari kelas-kelas sentimen tersebut. Hal ini mengindikasikan masih tingginya tingkat ketidakpuasan akan layanan jasa sektor ini, terlebih dengan adanya pandemi covid-19.

Pada periode tiga bulan pertama pandemi, analisis jendela waktu memberikan hasil bahwa covid-19 tidak hanya berkorelasi signifikan positif terhadap jumlah *tweet*, tetapi juga berkorelasi signifikan positif terhadap polaritas sentimen ‘Negatif’-nya di hampir semua penyedia layanan. Hal ini mengindikasikan bahwa bertambahnya jumlah layanan yang diberikan, diiringi juga dengan bertambahnya jumlah ketidakpuasan terhadap layanan yang bersangkutan. Data pada periode ini memberikan kesimpulan bahwa sistem layanan yang dimiliki belum cukup kuat atau belum siap menghadapi fluktuasi permintaan pengiriman.

Pada periode tiga bulan kedua pandemi, analisis sentimen jendela waktu memberikan hasil korelasi sedikit berbeda, dimana korelasi signifikan positif terjadi pada penyedia layanan JNE, Pos Indonesia, dan SiCepat, sedangkan penyedia layanan Tiki tidak lagi signifikan dan JNT tidak signifikan dengan nilai yang jauh lebih baik. Hal ini menunjukkan bahwa pada periode ini telah terjadi proses perbaikan pelayanan meskipun belum terjadi pada semua penyedia layanan pengiriman barang.

5.1.2 Pemodelan Topik

Pemodelan topik dilakukan untuk mengetahui topik-topik yang paling sering dibahas dalam dokumen. Adapun pemodelan topik dengan pendekatan jendela waktu juga dilakukan pada tiga periode terhadap data bersentimen ‘Negatif’, sama seperti pada analisis sentimen.

Pada periode sebelum pandemi, jumlah topik optimal yang diperoleh adalah 5 topik, diantaranya: (1) kecepatan dan jaminan layanan, (2) pelacakan dan *update* informasi, (3) *update* progres pengiriman, (4) sinkronisasi status barang, (5) konfirmasi pengiriman.

Pada periode tiga bulan pertama pandemi, jumlah topik optimal yang diperoleh adalah 6 topik, dimana beberapa diantaranya merupakan topik baru seperti: (1) layanan pelanggan, (2) pengantaran barang, sedangkan sisanya merupakan topik lama, seperti (3) kecepatan dan jaminan layanan, (4) pelacakan dan *update* informasi, (5) *update* progres pengiriman, dan (6) konfirmasi pengiriman. Keluhan terkait sinkronisasi status tidak lagi menjadi topik pembicaraan dalam periode ini.

Terakhir pada periode tiga bulan kedua pandemi, jumlah topik optimal yang diperoleh adalah 6 topik yang bersifat spesifik. Sejatinya semua topik pembicaraan tersebut merupakan topik yang sudah ada pada periode-periode sebelumnya yang dapat dikelompokkan menjadi 4 topik utama saja, yaitu: (1) pelacakan dan pembaharuan informasi, (2) konfirmasi pengiriman, (3) sinkronisasi informasi status barang, dan (4) kecepatan dan jaminan pengiriman.

Secara keseluruhan, tren topik yang ditulis terkait dengan polaritas sentimen ‘Negatif’ sebelum dan selama pandemi dapat dilihat pada Tabel 5.1.

Tabel 5.1. Rangkuman tren topik sebelum dan selama pandemi

| No | Topik | Periode | | |
|----|-----------------------------------|---------|-----------------|---------------|
| | | Sebelum | 3 bulan pertama | 3 bulan kedua |
| 1 | Kecepatan & jaminan layanan | ✓ | ✓ | ✓ |
| 2 | Pelacakan & pembaharuan informasi | ✓ | ✓ | ✓ |
| 3 | Progres pengiriman | ✓ | ✓ | - |
| 4 | Sinkronisasi status | ✓ | - | ✓ |
| 5 | Konfirmasi pengiriman | ✓ | ✓ | ✓ |
| 6 | Layanan pelanggan | - | ✓ | - |
| 7 | Pengantaran barang | - | ✓ | - |

5.2 Implikasi Penelitian

Berdasarkan penelitian yang telah dilakukan, dapat dijabarkan implikasi teoritis dan praktis yang dapat diperoleh, yaitu:

5.2.1 Implikasi Teoritis

- Pendekatan metode leksikon mempermudah dalam klasifikasi data latih (data *unsupervised*) bila dibandingkan dengan cara manual. Dengan pendekatan leksikon, cara manual hanya diperlukan untuk mengevaluasi dan memastikan hasil klasifikasi telah sesuai konteksnya.
- Polaritas sentimen pada data Twitter khususnya polaritas ‘Non-Negatif’ sangat sensitif terhadap adanya intervensi (promo, event), sehingga harus dilakukan analisis lebih mendalam untuk dapat mempergunakan polaritas ini sebagai parameter sentimen yang objektif.
- Penelitian ini menunjukkan bahwa tren sentimen dengan pendekatan *TFIDF-SVM* maupun tren topik dengan pendekatan *LDA-Mallet* dapat diketahui melalui pendekatan jendela waktu, dimana belum banyak penelitian yang menggunakan pendekatan keduanya secara bersama-sama dalam analisis teks.

5.2.2 Implikasi Praktis

Hasil penelitian ini kiranya dapat dipergunakan sebagai masukan bagi penyedia layanan pengiriman barang domestik di Indonesia. Penyajian analisis sentimen dan pemodelan topik tidak hanya dapat dipergunakan untuk mengetahui sentimen yang ada saat ini, tetapi juga dapat dipergunakan untuk perbaikan melalui evaluasi topik-topik sentimen ‘Negatif’ yang berhasil diekstraksi.

Sebagai bahan masukan, penelitian ini merekomendasikan beberapa topik bahasan yang patut dipertimbangkan dalam upaya evaluasi dan perbaikan. Topik-topik tersebut antara lain: (1) kecepatan & jaminan layanan, (2) pelacakan & pembaharuan informasi, dan (3) konfirmasi pengiriman. Topik-topik ini perlu menjadi prioritas perbaikan karena selalu muncul pada semua periode yang dipergunakan dalam penelitian.

5.3 Saran

Pada penelitian ini hanya memanfaatkan *tweet* dengan pengaturan bahasa Indonesia, sehingga pada penelitian selanjutnya dapat memanfaatkan *tweet* bahasa lain untuk dapat memperoleh hasil analisis seutuhnya dari keseluruhan data. Selain itu proses klasifikasi leksikal pada data latih masih mempergunakan sumber leksikon yang sangat terbatas dan memerlukan proses evaluasi manual yang cukup panjang, sehingga diperlukan

pengembangan sumber leksikon yang baik dan lengkap seperti yang ada pada bahasa Inggris.

Masih diperlukan perbaikan metode dalam proses *preparasi* data, agar mampu mendeteksi *tweet-tweet* yang tidak berkorelasi dengan layanan (*tweet* akun *dummy*, *tweet* promo, dan lain-lain) sehingga mampu menghasilkan analisis sentimen yang lebih objektif dan dapat memanfaatkan keseluruhan kelas sentimen yang ada, baik kelas sentimen ‘Negatif’, ‘Netral’, maupun ‘Positif’. Salah satu strateginya yang mungkin untuk diterapkan yaitu memasukkan proses pemodelan topik dalam tahap data *preprocessing*.

Dalam penelitian ini, analisis sentimen ‘Negatif’, ‘Netral’, maupun ‘Positif’ dilakukan terhadap keseluruhan data, sehingga untuk penelitian selanjutnya dapat digunakan dimensi kualitas layanan (*reliability*, *responsiveness*, *assurance*, *empathy*, dan *tangibles*) untuk mendapatkan evaluasi yang lebih baik dan spesifik. Secara teoritis, hal ini dapat dilakukan dengan memilah-milah istilah/kalimat sesuai dengan dimensi kualitas pelayanan masing-masing dalam konteks pelayanan pengiriman barang berdasarkan kata kunci yang relevan.

DAFTAR PUSTAKA

- Adriani, M., Asian, J., Nazief, B., Tahaghoghi, S. M., & Williams, H. E. (2007). Stemming Indonesian: A confix-stripping approach. *ACM Transactions on Asian Language Information Processing* 6 (4), 1-33.
- Ahuja, R., Chug, A., Kohli, S., Gupta, S., & Ahuja, P. (2019). The Impact of Features Extraction on the Sentiment Analysis. *International Conference on Pervasive Computing Advances and Applications – PerCAA 2019* (hal. 341-348). Jaipur, India: Elsevier.
- Ali, F., Kwak, D., Khan, P., El-Sappagh, S., Ali, A., Ullah, S., . . . Kwak, K.-S. (2019). Transportation sentiment analysis using word embedding and ontology-based topic modeling. *Knowledge-Based Systems* 174, 27-42.
- Annisa, R., Surjandari, I., & Zulkarnain. (2019). Opinion Mining on Mandalika Hotel Reviews Using Latent Dirichlet Allocation. *Procedia Computer Science* 161, 739-746.
- Bhargava, R., & Sharma, Y. (2017). MSATS: Multilingual Sentiment Analysis via Text Summarization. *7th International Conference on Cloud Computing, Data Science & Engineering* (hal. 71-76). Pilani: IEEE.
- Biraj Dahal, Sathish A. P. Kumar, & Zhenlong Li. (2019). Topic modeling and sentiment analysis of global climate change tweets. *Social Network Analysis and Mining* 9 (24). doi:10.1007/s13278-019-0568-8
- Blei, D. M., Ng, A. Y., & Jordan, M. I. (2003). Latent Dirichlet Allocation. *Journal of Machine Learning Research* 3 , 993-1022.
- Boser, B. E., Guyon, I. M., & Vapnik, V. N. (1992). A Training Algorithm for Optimal Margin Classifiers. *5th Annual Workshop on Computational Learning Theory (COLT '92)* (hal. 144-152). Pittsburgh Pennsylvania USA: Association for Computing Machinery.
- Boussaadi, S., Aliane, H., & Abdeldjalil, O. (2020). The Researchers Profile with Topic Modeling. *2nd International Conference on Electronics, Control, Optimization and Computer Science (ICECOCS)* (hal. 1-6). Kenitra, Morocco: IEEE.

- Calheiros, A. C., Moro, S., & Rita, P. (2017). Sentiment Classification of Consumer-Generated Online Reviews Using Topic Modeling. *Journal of Hospitality Marketing & Management* 26 (7), 675-693.
- Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: Synthetic Minority Over-sampling Technique. *Journal of Artificial Intelligence Research* 16, 321-357.
- Defianti, I. (2020, April 10). *10 Sektor Usaha Ini Tetap Diizinkan Beroperasi Selama PSBB*. Diambil kembali dari Liputan6 Web site: <https://www.liputan6.com/news/read/4224207/10-sektor-usaha-ini-tetap-diizinkan-beroperasi-selama-psbb>
- Dewi, S. (2016). Komparasi 5 Metode Algoritma Klasifikasi Data Mining pada Prediksi Keberhasilan Pemasaran Produk Layanan Perbankan. *Jurnal Techno Nusa Mandiri Vol. XIII (1)*, 60-66.
- El-Kassas, W. S., Salama, C. R., Rafea, A. A., & Mohamed, H. K. (2021). Automatic text summarization: A comprehensive survey. *Expert Systems with Applications* 165, 113679. doi:10.1016/j.eswa.2020.113679
- Huda, L., & Hidayat, A. A. (2020, Maret 19). *Pandemi Corona, Tren Kenaikan Jasa Logistik Naik Terus Tiap Hari*. Diambil kembali dari Tempo Web site: <https://bisnis.tempo.co/read/1321314/pandemi-corona-tren-kenaikan-jasa-logistik-naik-terus-tiap-hari/full&view=ok>
- J&T Express. (2021). *About Company J&T Express*. Diambil kembali dari J&T Express Web site: <https://www.jet.co.id/about/company>
- Jeong, B., Yoon, J., & Lee, J.-M. (2017). Social media mining for product planning: A product opportunity mining approach based on topic modeling and sentiment analysis. *International Journal of Information Management* 48, 280-290.
- JNE Express. (2021). *Profil Perusahaan JNE Express*. Diambil kembali dari JNE Express Web site: <https://www.jne.co.id/id/perusahaan/profil-perusahaan#>
- Kemp, S. (2021, Februari 18). *Digital 2021: Indonesia*. New York: We Are Social Inc. Diambil kembali dari We Are Social Website: <https://datareportal.com/reports/digital-2020-indonesia>

- Khoo, C. S., & Johnkhan, S. B. (2017). Lexicon-based sentiment analysis: Comparative evaluation of six sentiment lexicons. *Journal of Information Science* 44 (4), 491-511.
- Kominfo. (2013, November 7). *Kominfo : Pengguna Internet di Indonesia 63 Juta Orang*. Diambil kembali dari Kominfo Web site: https://kominfo.go.id/index.php/content/detail/3415/Kominfo+%3A+Pengguna+Internet+di+Indonesia+63+Juta+Orang/0/berita_satker#:~:text=Kebanyakan%20pengguna%20Twitter%20di%20Indonesia,jumlah%20pengguna%20700.000%20di%20Indonesia.
- Koto, F., & Rahmaningtyas, G. Y. (2017). InSet Lexicon: Evaluation of a Word List for Indonesian Sentiment Analysis in Microblogs. *2017 International Conference on Asian Language Processing (IALP)* (hal. 391-394). Singapore: IEEE.
- Liu, B. (2015). *Sentiment Analysis - Mining Opinions, Sentiments, and Emotins*. New York: Cambridge University Press.
- Luiz, W., Viegas, F., Alencar, R., Mourao, F., Salles, T., Carvalho, D., . . . Rocha, L. (2018). A Feature-Oriented Sentiment Rating for Mobile App Reviews. *WWW '18: Proceedings of the 2018 World Wide Web Conference* (hal. 1909-1918). Lyon, France: International World Wide Web Conferences Steering Committee Republic and Canton of GenevaSwitzerland.
- Mashabi, S., & Galih, B. (2020, September 03). *6 Bulan Pandemi Covid-19: Catatan tentang PSBB dan Penerapan Protokol Kesehatan...* Diambil kembali dari Kompas Web site: <https://nasional.kompas.com/read/2020/09/03/09002161/6-bulan-pandemi-covid-19-catatan-tentang-psbb-dan-penerapan-protokol?page=all>
- McCallum, A. K. (2002). MALLET: A Machine Learning for Language Toolkit. <http://mallet.cs.umass.edu>.
- Miner, G., Delen, D., Elder, J., Fast, A., Hill, T., & Nisbet, R. A. (2012). *Practical Text Mining and Statistical Analysis for Non-structured Text Data Applications*. Oxford, UK: Academic Press .
- Nugroho, A. S., Witarto, A. B., & Handoko, D. (2003). Support vector machine teori dan aplikasinya dalam bioinformatika. *Kuliah umum ilmukomputer. com*.

- Poria, E. C., Gelbukh, A., & Thelwall, M. (2017). Sentiment Analysis Is a Big Suitcase. *IEEE Computer Society*, 74-80.
- Pos Indonesia. (2021). *Sejarah Pos Indonesia*. Diambil kembali dari Pos Indonesia Web site: <https://www.posindonesia.co.id/en/content/sejarah-pos>
- PT. SiCepat Ekspres Indonesia. (2020). *SiCepat Ekspres*. Diambil kembali dari SiCepat Web site: <https://www.sicepat.com/>
- Rao, T., & Srivastava, S. (2012). Analyzing stock market movements using Twitter sentiment analysis. *Proceedings of the 2012 International Conference on Advances in Social Networks Analysis and Mining (ASONAM 2012)* (hal. 119-123). NW Washington DC, USA: IEEE Computer Society .
- Richins, M. L. (1984). Word of Mouth Communication As Negative Information. *Advances in Consumer Research Volume 11*, 697-702.
- Rocca, J. (2019, Juli 1). *Bayesian inference problem, MCMC and variational inference*. Diambil kembali dari The Medium Web site: <https://towardsdatascience.com/bayesian-inference-problem-mcmc-and-variational-inference-25a8aa9bce29>
- Rus, A. M., Annisa, R., Surjandari, I., & Zulkarnain. (2019). Measuring Hotel Service Quality in Borobudur Temple Using Opinion Mining. *16th International Conference on Service Systems and Service Management (ICSSSM)* (hal. 19112662). Shenzhen, China: IEEE. doi:10.1109/ICSSSM.2019.8887650
- SF Media Solutions - Web Design and Online Marketing. (2017, Desember 20). *6 Reasons Why Social Media Reviews are Important*. Diambil kembali dari SF Media Solutions - Web Design and Online Marketing Web site: <https://sf.media/insights/social-media/6-reasons-why-social-media-reviews-are-important>
- Tempo. (2020). *Seberapa Cerah Dampak Bisnis Online Bagi Pengusaha Jasa Pengiriman Barang*. Jakarta: Tempo Data Science.
- TIKI. (2020). *Tentang TIKI*. Diambil kembali dari TIKI Web site: <https://tiki.id/id/tentang-tiki>

- Tuhuteru, H., & Iriani, A. (2018). Analisis sentimen perusahaan listrik negara cabang Ambon menggunakan metode support vector machine dan naive bayes classifier. *Jurnal Informatika: Jurnal Pengembangan IT (JPIT) Vol.03*, 394-401. doi:10.30591/jpit.v3i3.977
- Vania, C., Ibrahim, M., & Adriani, M. (2014). Sentiment Lexicon Generation for an Under-Resourced Language. *International Journal of Computational Linguistics and Applications (IJCLA) 5 (1)*, 59-72.
- Vijayarani, S., & Dhayanand, S. (2015). Data mining classification algorithms for kidney disease prediction. *International Journal on Cybernetics Informatics 4 (4)*, 13-25.
- Wang, M., Wu, H., Zhang, T., & Zhu, S. (2020). Identifying critical outbreak time window of controversial events based on sentiment analysis. *PLoS One 15*, 1-20. doi:10.1371/journal.pone.0241355
- Worldometers. (2021, Maret 17). *Covid-19 Coronavirus Pandemic*. Diambil kembali dari Worldometers Web site: https://www.worldometers.info/coronavirus/?utm_campaign=homeAdvegas1?
- Yoo, S., Song, J., & Jeong, O. (2018). Social media contents based sentiment analysis and prediction system. *Expert Systems with Applications Volume 105*, 102-111.
- Zacharias, C. (2020, April 29). *TWINT - Twitter Intelligence Tool*. Diambil kembali dari PyPI Web site: <https://pypi.org/project/twint/>
- Zulkarnain, Surjandari, I., & Wayasti, R. A. (2018). Sentiment Analysis for Mining Customer Opinion on Twitter: A Case Study of Ride-Hailing Service Provider. *5th International Conference on Information Science and Control Engineering* (hal. 512-516). Zhengzhou, Henan, China: IEEE.

LAMPIRAN-LAMPIRAN

Lampiran 1. Kode program proses stemming dengan pustaka Sastrawi

```
# create stemmer
factory = StemmerFactory()
stemmer = factory.create_stemmer()

# stemmed
def stemmed_wrapper(term):
    return stemmer.stem(term)

term_dict = {}

for document in df2['sw_token_tweet']:
    for term in document:
        if term not in term_dict:
            term_dict[term] = ' '

print(len(term_dict))
print("-----")

for term in term_dict:
    term_dict[term] = stemmed_wrapper(term)
    print(term,":", term_dict[term])

print(term_dict)
print("-----")

# apply stemmed term to dataframe
def get_stemmed_term(document):
```

```

return [term_dict[term] for term in document]

df2['stem_token_tweet'] = df2['sw_token_tweet'].swifter.apply(get_stemmed_term)

```

Lampiran 2. Kode program ekstraksi fitur dengan pendekatan leksikal

```

sencol = []
senrow = np.array([])
nsen = 0
factory = StemmerFactory()
stemmer = factory.create_stemmer()
sentiment_list = []
# function to write the word's sentiment if it is founded
def found_word(ind, words, word, sen, sencol, sentiment, add):
    # if it is already included in the bag of words matrix, then just increase the value
    if word in sencol:
        sen[sencol.index(word)] += 1
    else:
        #if not, than add new word
        sencol.append(word)
        sen.append(1)
        add += 1
    #if there is a negation word before it, the sentiment would be the negation of it's sentiment
    if (words[ind-1] in negasi):
        sentiment += -(lexicon['weight'][lexicon_word.index(word)]+1)
    else:
        sentiment += lexicon['weight'][lexicon_word.index(word)]

    return sen, sencol, sentiment, add

# checking every words, if they are appear in the lexicon, and then calculate their sentiment if they
do

```

```

for i in range(len(vendor_df1)):
    nsen = senrow.shape[0]
    words = word_tokenize(vendor_df1['WSW_tweet'][i])
    sentiment = 0
    add = 0
    prev = [0 for ii in range(len(words))]
    n_words = len(words)
    if len(sencol)>0:
        sen =[0 for j in range(len(sencol))]
    else:
        sen =[]

    for word in words:
        ind = words.index(word)
        # check whether they are included in the lexicon
        if word in lexicon_word :
            sen,sencol,sentiment,add= found_word(ind,words,word,sen,sencol,sentiment,add)
        else:
            # if not, then check the root word
            kata_dasar = stemmer.stem(word)
            if kata_dasar in lexicon_word:
                sen,sencol,sentiment,add= found_word(ind,words,kata_dasar,sen,sencol,sentiment,add)
    if add>0:
        if i>0:
            if (nsen==0):
                senrow = np.zeros([i,add],dtype=int)
            elif(i!=nsen):
                padding_h = np.zeros([nsen,add],dtype=int)
                senrow = np.hstack((senrow,padding_h))
                padding_v = np.zeros([(i-nsen),senrow.shape[1]],dtype=int)
                senrow = np.vstack((senrow,padding_v))
            else:
                padding =np.zeros([nsen,add],dtype=int)
                senrow = np.hstack((senrow,padding))

```

```
        senrow = np.vstack((senrow, sen))
    if i==0:
        senrow = np.array(sen).reshape(1, len(sen))
    # if there isn't then just update the old matrix
    elif(nsen>0):
        senrow = np.vstack((senrow, sen))

    sentiment_list.append(sentiment)
    sencol.append('sentiment')
    sentiment_array = np.array(sentiment_list).reshape(senrow.shape[0], 1)
    sentiment_data = np.hstack((senrow, sentiment_array))
    df_sen = pd.DataFrame(sentiment_data, columns = sencol)
```