

Analisis Sentimen Sosial Media Twitter Menggunakan RNN Studi Kasus: Bantuan Sosial Covid-19

Christofel Grant Matthew Halim¹, Green Arther Sandag²,

Sistem Informasi
Universitas Klabat
Airmadidi, Indonesia

e-mail: ¹s21810164@student.unklab.ac.id, ²greensandag@unklab.ac.id

Abstrak

Isu di media sosial Twitter yang terjadi di Indonesia mengenai Bantuan Sosial COVID-19 di mana penyalurannya tidak tepat sasaran dan tidak meratanya bantuan yang diberikan kepada masyarakat menimbulkan kekhawatiran di lingkungan masyarakat. Isu yang ada ini menjadi topik diskusi dan perdebatan di antara masyarakat. Penelitian ini bertujuan untuk melakukan analisis sentimen terhadap isu Bantuan sosial COVID-19 di Indonesia menggunakan model dari Long Short-Term Memory (LSTM) yaitu BiLSTM. Pengumpulan data yang digunakan dalam penelitian ini diperoleh dengan cara scraping data tweets menggunakan Google colab. Penelitian ini menggunakan dataset sebanyak 10.052 data tweets. Kinerja dengan menggunakan metode BiLSTM ini menghasilkan performa tertinggi yaitu 88% accuracy, 89% recall, 89% precision, 75% MCC, 85% specificity, 89% f1-score, dan 87% balanced accuracy, dan jika dibandingkan dengan 3 metode lainnya yaitu LSTM dan GRU dengan selisih 1-2% untuk accuracy dan untuk RNN mencapai selisih 11% dan untuk performa lainnya memiliki selisih sebesar 14%.

Kata kunci: analisis sentimen, deep learning, LSTM, BiLSTM, GRU.

Abstract

The issue on Twitter social media that occurred in Indonesia regarding COVID-19 Social Assistance where the distribution was not right on target and the unequal distribution of assistance provided to the community caused concern in the community. This issue has become a topic of discussion and debate among the community. This study aims to analyze sentiment on the issue of Covid-19 social assistance in Indonesia using the Long Short-Term Memory (LSTM) model, namely BiLSTM. The data collection used in this study was obtained by scraping tweets data using Google Colab. This study uses a dataset of 10,052 tweets data. Performance using the BiLSTM method produces the highest performance, namely 88% accuracy, 89% recall, 89% precision, 75% MCC, 85% specificity, 89% f1-score, and 87% balanced accuracy, and when compared with 3 other methods, namely LSTM and GRU with a difference of 1-2% for accuracy and for RNN it reaches a difference of 11% and for other performances it has a difference of 14%.

Keywords: sentiment analysis, deep learning, LSTM, BiLSTM, GRU.

1. Pendahuluan

COVID-19 (*Coronavirus Disease 2019*) merupakan suatu wabah yang disebabkan oleh jenis Coronavirus yang baru yaitu jenis Sars-CoV-2. Pertama kali diketahui keberadaannya di Wuhan, Tiongkok pada tanggal 31 Desember 2019 [1]. Penyebaran COVID-19 ini, sangat cepat dan meluas ke sejumlah negara [2]. Seluruh penduduk di dunia merasakan musibah pandemi COVID-19, salah satunya Indonesia, COVID-19 memberikan dampak pada sektor Sosial, Pendidikan, dan sektor Perekonomian Indonesia [3]. Pemerintah Indonesia mengeluarkan kebijakan sejak adanya COVID-19. Kebijakan ini berdampak pada sektor perekonomian [4], kemudian tahun 2021, pemerintah Indonesia mengeluarkan kebijakan mengenai PPKM, agar dapat memutus penularan COVID-19 [5].

Sebagai bentuk implementasi dari kebijakan yang dikeluarkan oleh pemerintah, pemerintah harus melakukan pemberdayaan untuk masyarakat [6]. Kebijakan yang dilakukan yaitu bantuan pra-kerja, bantuan UMKM dan Bantuan Sosial COVID-19 [7].

Perkembangan teknologi dan informasi sangat berkembang pesat dan memberi pengaruh di seluruh dunia. Salah satu teknologi yang memberi pengaruh adalah layanan media sosial. Media sosial memberikan peran penting untuk membentuk opini masyarakat [8]. Salah satu media sosial yang digunakan untuk menampung opini pengguna yaitu Twitter. Twitter memiliki fitur tweets di mana ini disebut sebagai analisis

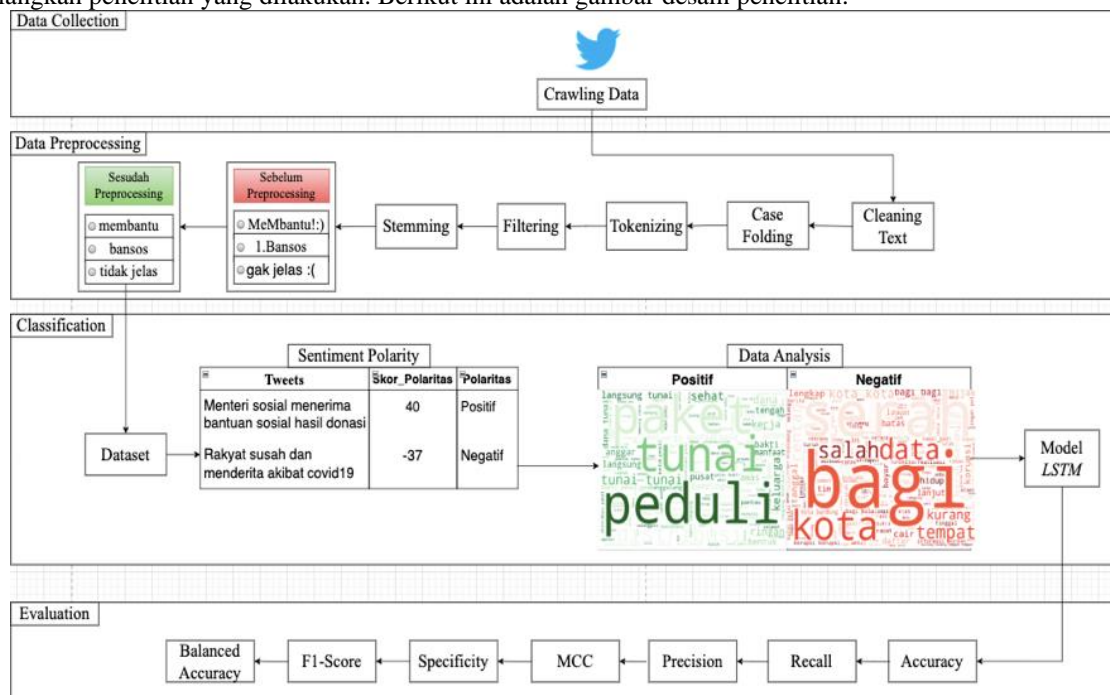
sentimen dan dapat mengekstrak semua opini pengguna *twitter*. *Twitter* merupakan media sosial yang secara cepat dapat mengabarkan pengalaman yang dirasakan oleh masyarakat. Oleh karena itu respon masyarakat Indonesia di media sosial *twitter* mengenai bantuan sosial *COVID-19* ini banyak dan berbeda-beda, ada yang memberikan sentimen positif atau negatif [9].

Penelitian ini menggunakan media sosial *twitter* untuk mengetahui sentimen masyarakat, terhadap program yang dibuat oleh pemerintah mengenai bantuan sosial *COVID-19*, apakah di terima atau tidak oleh masyarakat, adalah dengan cara melakukan analisis sentimen.

Analisis sentimen merupakan sebuah proses yang dilakukan untuk mengidentifikasi dan mengelompokkan sebuah opini dari sebuah teks yang bertujuan untuk menentukan apakah opini tersebut positif atau negatif.

2. Metode Penelitian

Dalam penelitian ini, peneliti membuat desain penelitian yang menjelaskan urutan atau langkah-langkah penelitian yang dilakukan. Berikut ini adalah gambar desain penelitian:



Gambar 1. Desain Penelitian

2.1. Data Collection dan Data Preprocessing

Pada tahap ini peneliti mengambil data yang ada pada *twitter*, yaitu berupa data *tweets* yang berhubungan dengan *Keyword* “bantuan sosial *COVID-19*”, dengan cara peneliti melakukan *scraping* dengan menggunakan *snsrape* di *Google colab*, dan data diambil per tanggal 31 Maret 2020 sampai 31 Desember 2020. Pada tahap ini, data hasil *scraping* yang didapat sebelumnya masih banyak mengandung *noise* maka dari itu di perlukan *Data Preprocessing* untuk menghilangkan *noise* dalam kata agar lebih terstruktur. Pada penelitian ini, tahap *Preprocessing* yang digunakan yaitu normalisasi kalimat, menghapus *URL*, *email*, *mention username*, *retweet*, *emoji*, *emoticons*, dan *Cleansing* seperti *Case folding*, *Tokenizing*, *Filtering*, dan *Stemming*. Selanjutnya ini akan menghasilkan sebuah *dataset* yang nantinya akan diklasifikasikan dan dianalisa berdasarkan sentimen positif dan negatif pada tahap berikutnya.

Selanjutnya setelah data sudah dibersihkan, akan dilakukan data labelling dengan menggunakan kamus *Lexicon based* Bahasa Indonesia, dengan cara menghitung skor sentimen untuk mengetahui kata yang memuat positif akan bernilai +1 atau lebih sedangkan negatif bernilai -1 atau lebih. Kemudian dari *dataset* yang sudah diberi label, selanjutnya peneliti mengklasifikasikan *Dataset* tersebut sesuai dengan kelasnya (*Sentiment Class*), untuk dibagi menjadi dua bagian yaitu positif dan negatif. Kemudian *dataset* tersebut divisualisasikan ke dalam *Word Cloud* dan akan dianalisa untuk melihat setiap kata-kata yang paling sering muncul, dan juga Peneliti akan melakukan visualisasi hasil kelas sentimen positif dan negatif dengan menggunakan *Histogram*. Selanjutnya sebelum *dataset* akan diproses ke dalam algoritma *Long Short-Term Memory (LSTM)*, peneliti akan melakukan *Feature Extraction* untuk mengubah bentuk sebuah

kata menjadi *vector* menggunakan *TF-IDF*, yang nantinya akan mempermudah dalam melewati tahapan klasifikasi menggunakan *Long Short-Term Memory (LSTM)*, dan peneliti menggunakan *Data Training* sebesar 80% untuk proses *LSTM*.

Pada tahap ini, peneliti mengevaluasi *Dataset* yang sudah diklasifikasi, di mana *Dataset* ini berisi kumpulan *Tweet* positif dan negatif, yang bertujuan untuk mengetahui tingkat *Accuracy*, *Recall*, *Specificity*, *Precision*, dan *Matthews Correlation Coefficient (MCC)* dari hasil perhitungan algoritma *Long Short-Term Memory (LSTM)*, dengan menggunakan 20% *Data Testing*, dan sisanya data *Data Training* [10], [11].

Accuracy:

$$(TP + TN) / (TP+FP+FN+TN) \tag{1}$$

Specificity:

$$(TN) / (TN + FP) \tag{2}$$

Recall:

$$(TP) / (TP + FN) \tag{3}$$

Precision:

$$(TP) / (TP + FP) \tag{4}$$


MCC:

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \tag{5}$$

2.2. Recurrent Neural Network (RNN)

Recurrent Neural Network (RNN) merupakan salah satu jenis arsitektur dari *Deep learning*. Saat memproses data Input, *RNN* digunakan berulang kali untuk memproses *Input*, seperti data yang berurutan (*Data Sequential*). Data yang dikumpulkan secara berurutan memiliki dua karakteristik utama yaitu, sampel yang diambil dari urutan waktu dan sampel dari rangkaian yang memiliki kaitan erat satu sama lain, Dengan cara *RNN* memproses Input dari sampel demi sampel secara berurutan. *RNN* memiliki kelemahan di mana *RNN* tidak bisa mempelajari ketergantungan jangka panjang, sehingga *RNN* tidak bisa mengolah input jangka panjang.

$$c^2 = a^2 + b^2 \tag{6}$$



Gambar 2. Arsitektur RNN

Recurrent Neural Network (RNN) berbeda dengan *Neural Network* tradisional, karena *RNN* beroperasi secara berulang dan setiap pemrosesan yang dihasilkan tidak hanya dipengaruhi oleh Input saat ini tetapi dipengaruhi oleh keadaan internal yang merupakan hasil dari pemrosesan Input sebelumnya atau selanjutnya dalam *RNN* dua arah dan biasanya *RNN* dipakai untuk melakukan suatu tugas yang berhubungan dengan *Time Series*, seperti ramalan untuk cuaca, contohnya cuaca di hari ini atau saat ini bergantung pada cuaca hari kemarin atau sebelumnya. Intinya sifat data yang menjadi fokus *RNN* adalah instans saat ini atau pada waktu sebelumnya, mempengaruhi instans selanjutnya. *RNN* memiliki beberapa varian, diantaranya *Long Short-Term Memory*, *Gated Recurrent Unit (GRU)*, dan *BiLSTM*. *Long Short-Term Memory (LSTM)* adalah salah satu jenis dari *Recurrent Neural Network (RNN)* dan juga merupakan salah satu *Deep Learning* yang bisa melakukan klasifikasi sentimen. Dalam masalah dependensi jangka panjang, *Long Short-Term Memory* bisa digunakan untuk masalah yang bersifat jangka panjang, karena jangka panjang merupakan salah satu perilaku yang dibangun ke dalam *LSTM*. *Long Short-Term Memory* juga mempunyai struktur urutan yang mirip dengan struktur *RNN*, tetapi memiliki perbedaan yang terletak di struktur modul pemrosesan berulang[12]. Persamaan *LSTM* dapat dilihat di bawah ini:

$$\begin{aligned}
 f_t &= \sigma_g(W_f x_t + U_f h_{t-1} + b_f) \\
 i_t &= \sigma_g(W_i x_t + U_i h_{t-1} + b_i) \\
 o_t &= \sigma_g(W_o x_t + U_o h_{t-1} + b_o) \\
 \tilde{c}_t &= \sigma_c(W_c x_t + U_c h_{t-1} + b_c) \\
 c_t &= f_t \circ c_{t-1} + i_t \circ \tilde{c}_t \\
 h_t &= o_t \circ \sigma_h(c_t)
 \end{aligned}
 \tag{7}$$

3. Hasil dan Pembahasan

3.1. Data Collection

Peneliti menggunakan library snsrape di *Google colab* untuk menarik *data tweets* di *twitter* yang berhubungan dengan *keyword* “bantuan sosial COVID-19” dengan menggunakan tanggal yang sudah ditentukan yaitu dari 2020-03-31 sampai 2020-12-31. Setelah melakukan scraping, peneliti mendapatkan data tweets sebanyak 13.216 data tweets. Selanjutnya semua *data tweets* ini akan di proses ke tahap selanjutnya yaitu *Data Preprocessing*.

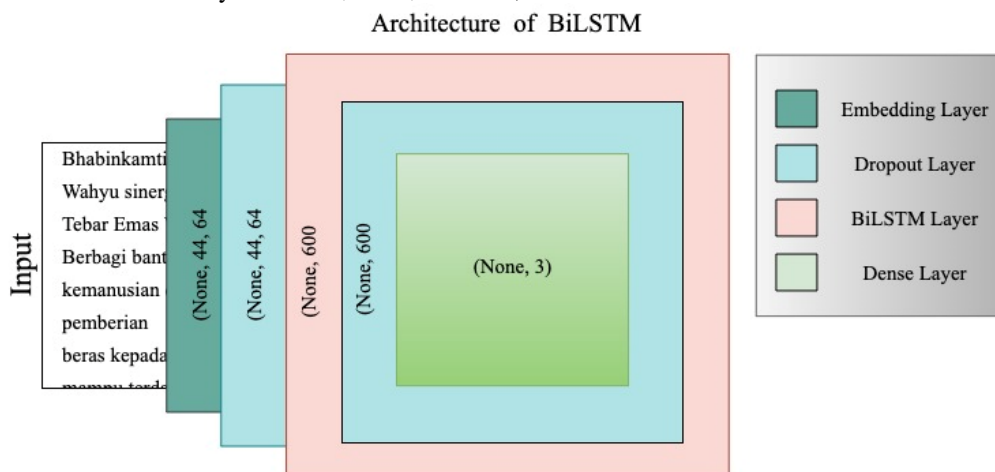
3.2. Data Preprocessing

Selanjutnya peneliti melakukan *data preprocessing* terhadap *data tweets* yang sudah di dapatkan. *Data tweets* yang didapatkan dari hasil scraping terdapat banyak kata-kata yang tidak memiliki arti dan juga masih terdapat banyak kata-kata yang tidak teratur sehingga ini akan mempersulit peneliti untuk melakukan analisa. Pada tahap *data preprocessing* ini akan dilakukan beberapa tahap seperti, *case folding*, *tokenizing*, *filtering*, dan *stemming* sehingga dalam tahap *data preprocessing* ini akan menyeleksi setiap kata-kata atau komentar apakah diperlukan atau tidak.

3.3. Klasifikasi

Selanjutnya peneliti melakukan pengklasifikasian terhadap *data tweets* yang di sudah melewati tahap *data preprocessing* untuk melihat polaritas *sentiment* dan *polarity score* dengan cara peneliti membagi data menjadi dua bagian, yaitu: positif dan negatif dengan menggunakan *library polarity / Lexicon Based* untuk Bahasa Indonesia dari <https://github.com/fajri91/InSet>. Total *data* setelah peneliti menentukan polaritas dari *data tweets* yaitu untuk positif sebanyak 5525 dan untuk negatif sebanyak 3719. Selanjutnya *data tweets* ini akan diproses ke tahap selanjutnya yaitu tahap *Data analysis*.

Pada tahap ini peneliti membuat model dan melakukan *training* (*‘fitting’*) terhadap *data training* untuk semua model *LSTM* yaitu *LSTM*, *GRU*, *BiLSTM*, dan *RNN*.



Gambar 3. Arsitektur BiLSTM

Dalam penelitian ini menggunakan data training yang telah dilakukan dalam proses pelabelan kalimat berdasarkan sentimen positive dan negative. Data yang sudah diolah dibagi menjadi dua bagian, 80% untuk training dan 20% untuk testing. Gambar 3 merupakan model arsitektur dari *BiLSTM*. Model ini

menggunakan empat lapisan utama yaitu lapisan *embedding*, lapisan *dropout*, lapisan *BiLSTM*, dan lapisan *dense*. Model serupa juga diterapkan pada model lainnya yaitu *LSTM*, *GRU*, dan *RNN*.

3.4. Evaluasi

Pada tahap terakhir, peneliti mengevaluasi hasil *metrics* seperti *Accuracy*, *Recall*, *Precision*, *Matthew Correlation Coefficient (MCC)*, *Specificity*, *F1-Score*, *Balanced_Accuracy* dari ke-empat model yang ada yaitu *LSTM*, *GRU*, *BiLSTM*, dan *RNN*. Tujuan dari evaluasi ini yaitu untuk melihat hasil kinerja dari setiap model yang sudah ditentukan dalam penelitian ini, agar dapat melihat model mana yang memiliki hasil kinerja terbaik.

TABEL 1. HASIL KINERJA DARI SETIAP MODEL

	Accuracy	Recall	Precision	MCC	Specificity	F1-Score	Balanced Accuracy
LSTM	86%	86%	90%	73%	87%	88%	86%
GRU	87%	91%	87%	73%	81%	89%	86%
BiLSTM	88%	89%	89%	75%	85%	89%	87%
RNN	77%	77%	82%	54%	75%	80%	77%

Berdasarkan Tabel 1, merupakan hasil *metrics* dari *BiLSTM* dan dapat dilihat nilai dari setiap *metrics* yaitu 88% accuracy, 89% recall, 89% precision, 75% mcc, 85% specificity, 89% f1-score, dan 87% balanced_accuracy. Berikut peneliti membuat tabel perbandingan hasil *metrics* seperti accuracy, recall, precision, mcc, specificity, F1-Score, Balanced_accuracy dari setiap model yang ada.

3.5. Analisis Word Cloud

Word Cloud merupakan visualisasi dari data berupa teks. *Word Cloud* dapat memvisualisasikan kata-kata dari *tweets* berdasarkan frekuensinya, di mana kata yang berukuran paling besar adalah kata yang memiliki frekuensi tertinggi. *Word Cloud* memiliki kegunaan untuk menampilkan kata-kata pada *tweets* yang sering muncul berdasarkan keyword “bansos COVID-19” di media sosial *twitter*. Berikut ini merupakan nama-nama pengguna *twitter* yang melakukan tweet di *twitter* dengan kata-kata *positive* paling banyak dan kata-kata *negative* paling banyak. Dan berikut adalah *word cloud* dari kata-kata *positive*, *negative*, dan *neutral* berdasarkan data *tweets* peneliti.



Gambar 4. Word Cloud positive negative neutral berdasarkan data tweet

Pada Gambar 4. *Word Cloud* disajikan dalam gradasi warna hijau untuk kata-kata *positive*, merah untuk kata-kata *negative* dan grey untuk kata-kata *neutral*. Bisa dilihat bahwa kata yang paling banyak dipakai pada *tweets* yang berpolaritas *positive* adalah “peduli”, contoh tweet yang memakai kata “peduli” adalah “bakti sosial dari relawan peduli covid berupa bantuan sembako yang akan diserahkan kepada masyarakat tidak mampu yang terdampak covid”. Selanjutnya kata yang banyak dipakai pada *tweets* yang berpolaritas *negative* adalah “bagi”, untuk contoh tweet yang menggunakan kata “bagi” adalah “bantuan sosial dampak covid jangan dipotong atau dibagi”. Jadi bisa diketahui bahwa, opini masyarakat yang *positive* mengarah kepada kepedulian terhadap masyarakat yang tidak mampu yang terdampak covid, sedangkan opini masyarakat yang *negative* mengarah kepada pembagian bantuan sosial yang diberikan tidak penuh atau tidak sesuai.

4. Kesimpulan

Berdasarkan hasil penelitian dan pengujian yang dilakukan untuk analisis sentimen *Tweet* bantuan sosial *COVID-19* dengan menggunakan model *Bidirectional LSTM (BiLSTM)*, mendapatkan hasil *accuracy* sebesar 88% yang berarti hasil analisis sentimen dengan model ini menghasilkan kinerja yang cukup baik. Analisis sentimen menggunakan model *BiLSTM* menghasilkan kinerja yang lebih baik dibandingkan ketiga model lainnya. Model yang dihasilkan dengan metode *BiLSTM* memiliki hasil *accuracy* 1-2% lebih baik dibandingkan dengan metode *LSTM* dan *GRU*, dan juga 11% lebih baik jika dibandingkan dengan metode *RNN*. Berdasarkan keyword yang digunakan dalam penelitian ini yaitu ‘bantuan sosial covid-19’, memiliki kecenderungan sentimen yang positive sebesar 55%.

Daftar Pustaka

- [1] L. Widayarsi *et al.*, “Prediksi Kasus Covid-19 Melalui Analisis Data Google Trend Di Indonesia: Pendekatan Metode Long Short Term Memory (Lstm),” *J. Saintika Unpam J. Sains dan Mat. Unpam*, vol. 3, no. 2, p. 161, 2021, doi: 10.32493/jsmu.v3i2.7786.
- [2] W. Rahmansyah, R. A. Qadri, R. R. A. Sakti, and S. Ikhsan, “Pemetaan Permasalahan Penyaluran Bantuan Sosial Untuk Penanganan Covid-19 Di Indonesia,” *J. Pajak dan Keuang. Negara*, vol. 2, no. 1, pp. 90–102, 2020, doi: 10.31092/jpkn.v2i1.995.
- [3] W. Gunawan and D. A. Kusuma, “Kegiatan Pemberian Bantuan Sosial Pandemi Covid-19 Di Desa Sekitar Kampus Unpad Jatinangor,” *Kumawula J. Pengabd. Kpd. Masy.*, vol. 3, no. 3, p. 465, 2021, doi: 10.24198/kumawula.v3i3.28626.
- [4] K. Prakerja *et al.*, “E-mail: Abstrak,” vol. 2, no. 1, 2021.
- [5] T. Krisdiyanto, “Analisis Sentimen Opini Masyarakat Indonesia Terhadap Kebijakan PPKM pada Media Sosial Twitter Menggunakan Naïve Bayes Clasifiers,” *J. CoreIT J. Has. Penelit. Ilmu Komput. dan Teknol. Inf.*, vol. 7, no. 1, p. 32, 2021, doi: 10.24014/coreit.v7i1.12945.
- [6] E. Resdiana, I. I. P., and N. I. Alfiah, “Edukasi Pencegahan Covid 19 Bagi Penerima Program Bansos Di Desa Longos Kabupaten Sumenep,” *Dharma LPPM*, vol. 1, no. 2, pp. 146–152, 2020, doi: 10.31315/dlppm.v1i2.4060.
- [7] V. Septiandika and M. D. Septiana, “Implementasi Inovasi Peraturan Bupati Probolinggo No 41 Tahun 2020 (Studi Pada Layanan Informasi Status Kepesertaan Bansos),” *JISIP J. Ilmu Sos. dan Ilmu Polit.*, vol. 10, no. 2, pp. 153–165, 2021, doi: 10.33366/jisip.v10i2.2299.
- [8] S. Adam, I. Noviyanto, and A. Prasetyo, “Pembentukan Opini Publik Program Bantuan Sosial COVID-19 Pemprov DKI Jakarta Melalui Media Sosial Instagram (Analisis Framing pada Akun Instagram @dkijakarta),” *J. Heal. Sains*, vol. 2, no. 1, pp. 145–161, 2021, doi: 10.46799/jsa.v2i1.173.
- [9] A. Novantirani, M. K. Sabariah, and V. Effendy, “Analisis Sentimen pada Twitter untuk Mengenai Penggunaan Transportasi Umum Darat Dalam Kota dengan Metode Support Vector Machine,” *e-Proceeding Eng.*, vol. 2, no. 1, pp. 1–7, 2015.
- [10] N. Hasdyna and R. K. Dinata, “Analisis Matthew Correlation Coefficient pada K-Nearest Neighbor dalam Klasifikasi Ikan Hias,” *INFORMAL Informatics J.*, vol. 5, no. 2, p. 57, 2020, doi: 10.19184/isj.v5i2.18907.
- [11] L. A. Andika, P. A. N. Azizah, and R. Respatiwulan, “Analisis Sentimen Masyarakat terhadap Hasil Quick Count Pemilihan Presiden Indonesia 2019 pada Media Sosial Twitter Menggunakan Metode Naive Bayes Classifier,” *Indones. J. Appl. Stat.*, vol. 2, no. 1, p. 34, 2019, doi: 10.13057/ijas.v2i1.29998.
- [12] G. A. Sandag, A. M. Manueke, and M. Walean, “Sentiment Analysis of COVID-19 Vaccine Tweets in Indonesia Using Recurrent Neural Network (RNN) Approach,” *3rd Int. Conf. Cybern. Intell. Syst. ICORIS 2021*, 2021, doi: 10.1109/ICORIS52787.2021.9649648.