

ANALISIS SENTIMEN TERHADAP KEBIJAKAN KULIAH DARING SELAMA PANDEMI MENGGUNAKAN PENDEKATAN *LEXICON BASED FEATURES* DAN *SUPPORT VECTOR MACHINE*

Natasya Eldha Oktaviana^{*1}, Yuita Arum Sari², Indriati³

^{1,2,3}Universitas Brawijaya, Malang

Email: ¹natasyaeldha@gmail.com, ²yuita@ub.ac.id, ³indriati.tif@ub.ac.id

^{*}Penulis Korespondensi

(Naskah masuk: 01 Oktober 2021, diterima untuk diterbitkan: 17 Februari 2022)

Abstrak

Adanya virus baru yaitu COVID-19 atau SARS-CoV-2 yang berasal dari Wuhan, China pada awal tahun 2020 telah menggemparkan seluruh warga dunia salah satunya Indonesia dan memiliki tingkat penularan yang tinggi. Sehingga untuk meminimalisir penyebaran COVID-19, pemerintah Indonesia menetapkan salah satu kebijakan dalam dunia pendidikan yaitu pembelajaran/perkuliah *online*. Kebijakan tersebut mengakibatkan seluruh penyebaran informasi berubah menjadi *online* dan memberikan dampak yang luas bagi keberlanjutan pendidikan di Indonesia. Hal tersebut menimbulkan kontroversi pada kalangan masyarakat dan banyak yang akhirnya beropini pada media sosial, salah satunya Twitter. Analisis sentimen berguna untuk mengetahui ketepatan komputasi sistem dalam mengenali pembicaraan pada Twitter mengenai kebijakan pembelajaran *online* cenderung bersentimen negatif atau positif dengan menggunakan metode *Support Vector Machine* dan *Lexicon Based Features*. Penggunaan *Lexicon Based Features* berpengaruh terhadap objek penelitian yang menghasilkan nilai *accuracy* 0,6, nilai *precision* 0,56, nilai *recall* 0,75, dan *fmeasure* 0,64 dengan parameter optimal dalam mencapai konvergensi yaitu λ (Lambda) = 0,7, nilai parameter γ (gamma) = 0,0001, nilai parameter C (Kompleksitas) = 0,0001, iterasi = 50, dan ϵ (Epsilon) = 0,00000001. Hal tersebut menunjukkan bahwa metode yang digunakan pada penelitian ini dapat mengenali pembicaraan data komentar pada Twitter karena dibuktikan dengan nilai *accuracy* yang cukup tinggi.

Kata kunci: COVID-19, Kebijakan Kuliah Daring, *Support Vector Machine*, *Lexicon Based Features*

SENTIMENT ANALYSIS AGAINST ONLINE LECTURE POLICY DURING THE PANDEMIC USING LEXICON BASED FEATURES APPROACH AND SUPPORT VECTOR MACHINE

Abstract

The existence of a new virus, namely COVID-19 or SARS-CoV-2, that come from Wuhan, China, in early 2020, has shocked all citizens of the world, including Indonesia, and has a high transmission rate. So to minimize the spread of COVID-19, the Indonesian government has set one policy in online learning/lectures. This policy resulted in all information dissemination being online and had a broad impact on education in Indonesia. This policy caused controversy among the public, and many ended up giving opinions on social media, one of which was Twitter. Sentiment analysis is useful for determining the timeliness of system computing in discussions on Twitter regarding online learning policies that tend to have negative or positive sentiments using the *Support Vector Machine* and *Lexicon Based Features* methods. The use of *Lexicon Based Features* affects the object of research which produces an *accuracy* value of 0.6, a *precision* value of 0.56, a *recall* value of 0.75, and a size of 0.64 with the optimal parameter in achieving convergence, namely (Lambda) = 0.7, the parameter value (gamma) = 0.0001, the parameter value (Complexity) = 0.0001, iterations = 50, and (Epsilon) = 0.00000001. This evaluation value shows that the method used in this study can recognize the conversation of comment data on Twitter because a fairly high *accuracy* value evidences it.

Keywords: COVID-19, online collage policy, *Support Vector Machine (SVM)*, *Lexicon Based Features*

1. PENDAHULUAN

Kemunculan virus baru yaitu COVID-19 atau SARS-CoV-2 yang berasal dari Wuhan, China pada tahun 2020 telah menggemparkan seluruh warga dunia salah satunya Indonesia. Virus ini menyerang sistem pernafasan manusia dan memiliki intensitas penyebaran yang tinggi. Sehingga untuk meminimalisir penyebaran virus, maka pemerintah Indonesia menetapkan beberapa kebijakan dalam dunia pendidikan salah satunya yaitu pembelajaran dan perkuliahan yang dilakukan secara daring (dalam jaringan) atau online untuk menghindari kontak langsung antar manusia, sehingga dapat menerapkan social distancing.

Kebijakan tersebut mengakibatkan seluruh penyebaran informasi berubah menjadi online dan memberikan dampak yang luas bagi keberlanjutan pendidikan di Indonesia. Survey yang dilakukan oleh Kementerian Pendidikan dan Kebudayaan (Kemendikbud) tahun 2020 kepada 1.067 guru mendapatkan kesimpulan bahwa kendala utama yang dirasakan oleh guru dan tenaga pendidikan saat menerapkan pembelajaran daring adalah terbatasnya fasilitas pendukung, manajemen pembelajaran yang kurang terampil, pemanfaatan media digital, dan kurangnya motivasi belajar dari siswa sebagai faktor pendukung internal (Kementerian Pendidikan dan Kebudayaan, 2020). Hal ini menimbulkan kontroversi dikalangan masyarakat mengenai kesiapan Indonesia dalam menunjang pembelajaran online.

Eksistensi media sosial sebagai salah satu wadah penyebaran informasi justru semakin mengalami peningkatan saat pandemi virus COVID-19 (Junawan & Laugu, 2020). Salah satunya yaitu Twitter, dimana media sosial ini memberikan kemudahan bagi penggunaanya dalam hal kebebasan berpendapat berupa tulisan maksimal 140 karakter. Berdasarkan report *Global Digital Overview 2020* oleh *We Are Social* menyebutkan bahwa Twitter berada di urutan kelima sosial media paling banyak digunakan di Indonesia sebesar 56% dari total 160 juta pengguna media sosial aktif di Indonesia.

Penelitian ini menggunakan analisis sentimen yang bertujuan untuk mengetahui ketepatan komputasi sistem dalam mengenali pembicaraan pada Twitter mengenai kebijakan pembelajaran *online* cenderung bersentimen negatif atau positif. Kredibilitas data pada Twitter juga diakui dalam penggunaan analisis sentimen (Al-Fadillah & Ramdhani, 2021). Dalam implementasinya, penelitian ini menggunakan pendekatan *Lexicon Based Features* untuk ekstraksi fitur berdasarkan makna kata yang bersentimen negatif atau positif, sehingga peranan lexical resources menjadi tolak ukur utama (Vania, et al., 2014). Sementara itu, untuk melakukan klasifikasi komentar Twitter yang bersentimen negatif atau positif yaitu dengan memanfaatkan metode Support Vector Machine (SVM) karena kompleksitas, akurasi serta kecepatan

metode saat mengelola data berdimensi tinggi (Desai & Mehta, 2016). Metode SVM juga tidak terlalu sensitive dalam imbalanced dataset karena hipotesa yang dilakukan oleh metode tersebut hanya berpatokan pada data yang telah menjadi support vector (NOMLENI, 2015).

Agar penelitian ini mendapatkan hasil sesuai dengan yang diharapkan, terdapat beberapa batasan masalah diantaranya: (1) Data yang digunakan pada proses penelitian yaitu terkait ulasan terhadap kebijakan perkuliahan dan pembelajaran daring yang berasal dari media sosial Twitter. (2) Data yang digunakan menggunakan Bahasa Indonesia sebanyak 350 data ulasan yang dibagi menjadi 300 data latih dan 50 data uji. (3) Pengambilan data dimulai dari bulan Juni hingga Agustus 2020. (4) Menghasilkan output berupa klasifikasi data komentar Twitter mengenai pembelajaran *online* cenderung bersentimen negatif atau positif.

Analisis Sentimen

Analisis Sentimen adalah studi komputasi dalam mengenali dan mengekspresikan opini, sentiment, evaluasi, sikap, emosi, subjektivitas, penilaian atau pandangan yang terdapat pada suatu teks. Analisis sentimen juga dapat diartikan sebagai temuan dari polaritas teks dan mengklasifikasikannya menjadi positif atau negatif yang dapat membantu dalam evaluasi sebuah produk atau kinerja, serta dalam hal pengambilan keputusan juga (Mangat, et al., 2017).

Lexicon Based Features

Pemberian bobot didasarkan pada kamus atau *lexicon* dan bobot yang diberikan dilakukan pada kata yang bersentimen negatif atau positif disebut dengan *Lexicon Based Features* (Kurniawan, 2019). Langkah pertama dalam proses pembobotan ini yaitu dengan cara mengimplikasikan kamus atau *lexicon* yang mengandung sentimen, atau yang disebut dengan *sentiment dictioneries*. Proses perhitungan dimulai dari mencari nilai *lexicon* berdasarkan kamus, kemudian hasil tersebut dilakukan normalisasi min-max yang memiliki rentang nilai 0,1 dan 0,9.

Support Vector Machine (SVM)

SVM merupakan sistem pembelajaran yang menggunakan ruang hipotesa berupa fungsi linear pada sebuah ruang fitur (*feature space*) yang berdimensi tinggi, dilatih pada parameter sebagai algoritma pembelajaran yang berdasar pada teori optimasi dengan mengimplementasikan *learning bias* yang berasal dari pembelajaran statistic. Metode ini bekerja dengan cara mencari *hyperplane* terbaik dengan memaksimalkan jarak antar kelas. *Hyperplane* merupakan sebuah fungsi yang digunakan untuk memisahkan dua kelas dan digunakan untuk klasifikasi dalam ruang kelas pada dimensi yang lebih tinggi. SVM menggunakan kernel trik dalam mentransformasikan data ke ruang dimensi

yang lebih besar untuk memisahkan data secara *linear*. Terdapat beberapa fungsi kernel yang umum digunakan antara lain *Linear*, *Polynomial*, *Radial Basis Function* (RBF).

Sequential Learning

Metode *sequential learning* pada penelitian sebelumnya dilakukan untuk pengembangan SVM agar mendapatkan *hyperplane* dalam mencapai solusi yang optimal pada data yang berdimensi tinggi, serta mempercepat proses iterasi tanpa membutuhkan waktu yang lama. Langkah-langkah dalam melakukan *sequential learning* antara lain: (1) Inisialisasi variabel yang dibutuhkan dalam perhitungan *sequential learning* yaitu λ (lambda), γ (learning rate), C (complexity), ε (epsilon), dan jumlah iterasi maksimum; (2) Inisialisasi $\alpha_i = 0$ dan menghitung matrik Hessian D_{ij} menggunakan Persamaan (1);

$$D_{ij} = y_i y_j (K(x_i x_j) + \lambda^2) \quad (1)$$

(3) Melakukan perhitungan untuk memperbarui nilai E (error) dan α (alfa) menggunakan Persamaan (2), Persamaan (3), dan Persamaan (4).

$$E_i = \sum_{i=0}^N \alpha_i D_{ij} \quad (2)$$

$$\delta \alpha_i = \min\{\max[\gamma(1 - E_i) - \alpha_i], C - \alpha_i\} \quad (3)$$

$$\alpha_i = \alpha_i + \delta \alpha_i \quad (4)$$

(4) Lakukan perulangan pada langkah ketiga sampai mencapai batas iterasi atau mendapatkan nilai $\max(|\delta \alpha|) < \varepsilon$; (5) Setelah memperoleh nilai α dan *support vector* (SV), kemudian mengambil perhitungan kernel pada data dengan nilai $\alpha > 0$ dan dilanjutkan dengan perhitungan bias menggunakan persamaan (5).

$$b = -\frac{1}{2} (\sum_{i=0}^N \alpha_i y_i K(x_i x^-) + \sum_{i=0}^N \alpha_i y_i K(x_i x^+)) \quad (5)$$

(6) Langkah terakhir yaitu menghitung nilai fungsi $f(x)$ menggunakan Persamaan (6).

$$f(x) = \sum_{i=0}^N \alpha_i y_i K(x_i, x) + b \quad (6)$$

2. METODE PENELITIAN

Metodologi penelitian berisikan tahapan penelitian yang terstruktur dalam melakukan analisis sentimen terhadap kebijakan pemerintah mengenai pembelajaran/perkuliah *online* pada media sosial Twitter.

Teknik Pengumpulan Data

Dokumen yang dikumpulkan sebagai data penelitian berasal dari media sosial Twitter dan mencakup data komentar berbahasa Indonesia dari tiap pengguna. *Crawling data* pada twitter menggunakan *library twint* mulai dari bulan Juni hingga Agustus 2020 sebanyak 400 data. Kemudian data tersebut dilakukan filter secara manual untuk membersihkan data dari noise yang meliputi terlalu banyak emotikon, huruf yang berulang, dan lain-lain. Sehingga diperoleh total keseluruhan data sebanyak 350 data yang terbagi menjadi 300 data latih dan 50 data uji.

Proses Text Preprocessing

Text Preprocessing merupakan tahap yang penting sebelum melakukan sentimen analisis untuk mendapatkan hasil akurasi yang lebih tinggi (Angiani, et al., 2016). Tahapan dari *preprocessing* yang dilakukan pada penelitian ini antara lain *Case Folding* untuk menyetarakan semua huruf menjadi *lowercase*. *Data Cleaning* dilakukan proses penghilangan *noise* atau menghapus seluruh karakter selain huruf. Pada suatu *tweet* pastinya memiliki *noise* yang beragam seperti tanda baca, hashtag (#). Setelah itu *stopword removal* digunakan untuk mengurangi jumlah kata yang tidak penting pada dokumen, kata yang dihapus berdasarkan daftar kata yang terdapat pada stop list Tala. *Stemming* digunakan untuk menemukan kata dasar pada sebuah kata dan menggantinya berdasarkan struktur tata bahasa Indonesia yang benar. Proses terakhir yaitu *Tokenization* digunakan untuk memecah dokumen menjadi potongan token. Tokenisasi yang dilakukan adalah memisah kalimat berdasarkan karakter spasi.


Pembobotan Kata

Pembobotan kata merupakan sebuah teknik pengindeksan kata dengan cara memberikan bobot pada setiap kata yang terdapat pada setiap dokumen. Bobot yang diberikan pada setiap kata yaitu berdasarkan kepentingan kata tersebut pada dokumen. Pembobotan kata yang dilakukan pada penelitian ini dipengaruhi tiga faktor yaitu *term frequency*, *inverse document frequency* (IDF), dan *document length* (Jones, et al., 2000). Dimulai dengan mencari *Term Frequency* (TF), *Document Frequency* (DF), *Inverse Document Frequency* (IDF), dan nilai TF-IDF.

Implementasi Algoritma

Setelah data dibersihkan pada proses *preprocessing* dan dihitung frekuensinya melalui proses pembobotan kata. Selanjutnya yaitu implementasi pendekatan *Lexicon Based Features* untuk mengekstraksi fitur menggunakan dan dilakukan klasifikasi kelas dokumen menggunakan metode SVM untuk mengetahui kecenderungan dokumen bersentimen negatif atau positif. Langkah terakhir yaitu evaluasi metode SVM menggunakan *confusion matrix* yang nantinya akan mendapatkan

hasil *accuracy*, *precision*, *recall*, dan *f-measure*. Diagram alir perancangan algoritma ditunjukkan pada Gambar 1.



Gambar 1. Diagram Alir Perancangan Algoritma

3. PENGUJIAN

Pengujian Parameter SVM

Proses pengujian diawali dengan pengujian parameter SVM. Parameter yang diuji pada metode SVM antara lain nilai parameter λ (lambda), nilai parameter γ (gamma), nilai parameter C (kompleksitas), jumlah parameter iterasi, dan nilai parameter ϵ (epsilon).

Pengujian pertama mencari nilai parameter λ (lambda) dengan rentang nilai 0,001 – 4. Karena parameter ini merupakan pengujian pertama, maka parameter lain diinisialisasi dengan nilai 1 dengan iterasi sebanyak 50 iterasi. Hasil dari pengujian parameter nilai λ (lambda) ditunjukkan pada Tabel 1.

Tabel 1. Hasil Pengujian Nilai Parameter Lambda

Nilai λ	Evaluasi			
	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F-Measure</i>
0,001	0,46	0,4	0,25	0,31
0,1	0,46	0,4	0,25	0,31
0,3	0,46	0,4	0,25	0,31
0,5	0,48	0,44	0,29	0,35
0,7	0,5	0,47	0,29	0,36

Setelah mendapatkan hasil nilai parameter optimal λ (lambda) yaitu 0,7. Kemudian dilakukan pengujian nilai parameter γ (gamma) dengan rentang nilai 0,0001 – 1 yang ditunjukkan pada Tabel 2.

Tabel 2. Hasil Pengujian Nilai Parameter γ (gamma)

Nilai γ	Evaluasi			
	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F-Measure</i>
0,0001	0,52	0,5	0,58	0,54
0,001	0,42	0,14	0,42	0,06
0,3	0,46	0,4	0,25	0,31
0,5	0,48	0,44	0,29	0,35
0,7	0,5	0,47	0,29	0,36

Hasil parameter optimal gamma yaitu 0,0001 setelah itu digunakan untuk pengujian nilai parameter

C (kompleksitas) dengan rentang nilai 0,0001 – 1 yang ditunjukkan pada Tabel 3.

Tabel 3. Hasil Pengujian Nilai Parameter C (Kompleksitas)

Nilai C	Evaluasi			
	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F-Measure</i>
0,0001	0,6	0,56	0,75	0,64
0,001	0,6	0,56	0,75	0,64
0,01	0,52	0,5	0,58	0,54
0,1	0,52	0,5	0,58	0,54
0,0001	0,6	0,56	0,75	0,64

Hasil optimal parameter C juga mendapatkan nilai 0,001 sebagai nilai optimal pada penelitian ini. Kemudian dilakukan pengujian nilai iterasi sebanyak 50 – 90 iterasi yang ditunjukkan pada Tabel 4.

Tabel 4. Hasil Pengujian Nilai Parameter Iterasi

Nilai Iterasi	Evaluasi			
	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F-Measure</i>
50	0,6	0,56	0,75	0,64
60	0,6	0,56	0,75	0,64
70	0,6	0,56	0,75	0,64
80	0,6	0,56	0,75	0,64
90	0,6	0,56	0,75	0,64

Pada penelitian ini didapatkan jumlah iterasi sebanyak 50 sudah menghasilkan nilai evaluasi yang konvergen. Kemudian dengan menggunakan nilai-nilai optimal dari parameter sebelumnya, dilakukan pengujian parameter SVM terakhir yaitu ϵ (epsilon) dengan rentang 0,00000001 – 0,0001 yang ditunjukkan pada Tabel 5.

Tabel 5. Hasil Pengujian Nilai Parameter ϵ (epsilon)

Nilai Iterasi	Evaluasi			
	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F-Measure</i>
0,00000001	0,6	0,56	0,75	0,64
0,0000001	0,6	0,56	0,75	0,64
0,000001	0,6	0,56	0,75	0,64
0,00001	0,6	0,56	0,75	0,64
0,0001	0,6	0,56	0,75	0,64


Pengujian optimal parameter SVM mendapatkan nilai λ (lambda) = 0,7, nilai γ (gamma) = 0,0001, nilai C (kompleksitas) = 0,0001, iterasi = 50, dan ϵ (epsilon) = 0,00000001. Nilai parameter optimal dari SVM akan digunakan untuk pengujian pengaruh penggunaan *Lexicon Based Features* pada objek penelitian ini.

Pengujian Pengaruh Penggunaan *Lexicon Based Features*

Tahapan ini dilakukan uji perbandingan sistem terhadap penggunaan metode ekstraksi fitur berupa *lexicon based features* pada proses klasifikasi data objek penelitian dan dikomparasikan dengan sistem tanpa penggunaan *lexicon based features*. Hasil pengujian ditunjukkan pada Tabel 6.

Tabel 6. Hasil Pengujian Penggunaan *Lexicon Based Features*

Hasil Evaluasi	<i>Lexicon based features</i>	Tanpa <i>lexicon based features</i>
<i>Accuracy</i>	0,6	0,48
<i>Precision</i>	0,56	0,46
<i>Recall</i>	0,75	0,58
<i>Fmeasure</i>	0,64	0,52


Gambar 2. Hasil Perbandingan Pengujian Penggunaan *Lexicon Based Features*

Berdasarkan pada Gambar 2 menunjukkan bahwa hasil penelitian yang menggunakan metode *Support Vector Machine* dan *Lexicon Based Features* memberikan nilai evaluasi yang lebih tinggi daripada metode SVM tanpa menggunakan menggunakan pendekatan *Lexicon Based Feature* dengan nilai akhir *accuracy* 0,6, nilai *precision* 0,56, nilai *recall* 0,75, dan *fmeasure* 0,64 untuk mendapatkan nilai alpha yang konvergen.

4. HASIL DAN PEMBAHASAN

Sistem yang telah dirancang menggunakan SVM dan *lexicon based features* dapat digunakan untuk mengenali pembicaraan pada Twitter mengenai kebijakan pembelajaran *online*. Karena nilai *confussion matrix* pada data uji sebanyak 50 data yang terdapat pada Tabel 7 menunjukkan bahwa sistem dapat membaca data yang sudah dilatih sebelumnya dengan tepat.

Tabel 7. *Confussion matrix* Data Uji

Hasil Evaluasi	Kelas hasil prediksi	
	Negatif	Positif
Kelas sebenarnya	Negatif	12
	Positif	6

Pada implementasi pendekatan *lexicon based features* dan SVM, akurasi sistem sangat bergantung pada seberapa banyak kata pada dokumen yang sesuai pada kamus (*lexicon*) sehingga tidak semua kata yang seharusnya bersentimen positif atau negatif terdapat pada *lexical resources* dan mengakibatkan kesalahan pada proses klasifikasi dokumen tersebut. Contohnya pada kalimat “gw kira kuliah online nilainya kalo ga bagus bgt, ya jeblok, kok di gw ga ngefek apa2 ya sama aja” yang kemudian di proses pada *text preprocessing* menghasilkan beberapa *term* “gw”,

“kira”, “kuliah”, “online”, “nilainya”, “kalo”, “ga”, “bagus”, “bgt”, “ya”, “jeblok”, “kok”, “di”, “gw”, “ga”, “ngefek”, “apa”, “ya”, “sama”, “aja” yang menghasilkan nilai 0 pada saat dicocokkan pada *lexical resource* karena beberapa *term* tersebut tidak ada dalam kamus. Sehingga dapat mengurangi nilai akurasi sistem dan hasil klasifikasi dokumen yang kurang tepat.

5. KESIMPULAN DAN SARAN

Metode SVM dan pendekatan *lexicon based features* dapat diimplementasikan pada penelitian analisis sentimen terhadap kebijakan pembelajaran *online* selama pandemi COVID-19 dengan parameter optimal pada SVM untuk mendapatkan nilai alpha yang konvergen yaitu λ (Lambda) = 0,7, nilai parameter γ (gamma) = 0,0001, nilai parameter C (Kompleksitas) = 0,0001, iterasi = 50, dan ϵ (Epsilon) = 0,00000001. Hasil evaluasi sistem dalam mengenali kelas sentimen pada data komentar pengguna Twitter juga memperoleh peningkatan setelah menggunakan *lexicon based features* yaitu dengan nilai *accuracy* 0,6, nilai *precision* 0,56, nilai *recall* 0,75, dan *fmeasure* 0,64 dibandingkan proses klasifikasi tanpa *Lexicon Based Feature* yang hanya menghasilkan nilai *accuracy* 0,48, nilai *precision* 0,46, nilai *recall* 0,58, dan nilai *fmeasure* 0,52. Dimana nilai evaluasi tersebut meningkat sebanyak 12% daripada metode SVM yang tidak menggunakan pendekatan *lexicon based features*.

Terdapat beberapa saran pada penelitian yang bisa digunakan untuk mendapatkan hasil penelitian serupa yang lebih baik, diantaranya: (1) Menambahkan label dokumen menjadi tiga yaitu negatif, positif, dan netral; (2) Mencari kamus/*Lexical Resource* yang lebih lengkap dalam menghimpun kata; dan (3) Menambahkan jumlah data latih pada penelitian yang akan dilakukan agar dapat meningkatkan akurasi sistem.

DAFTAR PUSTAKA

- AL-FADILLAH, R. H. & RAMDHANI, N., 2021. Analisis Sentimen Pengguna Twitter Terhadap Belajar Daring Selama Pandemi Covid-19 Dengan Deep Learning. s.l., ResearchGate.
- ANGIANI, G. ET AL., 2016. A Comparison between Preprocessing Techniques for Sentiment Analysis in Twitter. Cagliari, <https://www.researchgate.net/publication/311615347>.
- DESAI, M. & MEHTA, M. A., 2016. Techniques for Sentiment Analysis of Twitter Data: A Comprehensive Survey.. [Online] Available at: <https://ieeexplore.ieee.org/document/7813707>. [Diakses 25 September 2020].

- HARAHAP, E. H., MUFLIKHAH, L. & RAHAYUDI, B., 2018. Implementasi Algoritma Support Vector Machine (SVM) Untuk Penentuan Seleksi Atlet Pancak Silat. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, Volume 2, pp. 3843-3848.
- JUNAWAN, H. & LAUGU, N., 2020. Eksistensi Media Sosial, Youtube, Instagram dan Whatsapp Ditengah Pandemi Covid-19 Dikalangan Masyarakat Virtual Indonesia. *Baitul Ulum: Jurnal Ilmu Perpustakaan dan Informasi*, Volume 4.
- KAMAL, R. M. & RAINARLI, E., 2019. Analisis Sentimen Cyberbullying Pada Komentar Facebook Dengan Metode Klasifikasi Support Vector Machine. Program Studi Teknik Informatika Fakultas Teknik dan Ilmu Komputer Universitas Komputer Indonesia.
- KEMENTERIAN PENDIDIKAN DAN KEBUDAYAAN, 2020. Analisis Survei Cepat Pembelajaran dari Rumah dalam Masa Pencegahan COVID-19, s.l.: s.n.
- KURNIAWAN, A., 2019. Analisis Sentimen Opini Film Menggunakan Metode Naive Bayes dan Lexicon Based Features. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 3(9), pp. 8335 - 8342.
- LAILIYAH, M., 2017. Sentiment Analysis Menggunakan Rule Based Method Pada Data Pengaduan Publik Berbasis Lexical Resources.
- N., MANGAT, V. & KAUR, H., 2017. A survey of sentiment analysis techniques. s.l., 2017 International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC).
- NOMLENI, P., 2015. Sentiment Analysis Menggunakan Support Vector Machine (Svm). Repository Insitute Teknologi Sepuluh Nopember.
- WIJAYA, K. D. Y. & KARYAWATI, E., 2020. The Effects of Different Kernels in SVM Sentiment Analysis on Mass Social Distancing. *Jurnal Elektronik Ilmu Komputer Udayana*, Volume 9.