

ANALISIS SENTIMEN TERHADAP PEMBELAJARAN DARING DI INDONESIA MENGGUNAKAN *SUPPORT VECTOR MACHINE* (SVM)

Alfiyah Nur Indraini¹, Iin Ernawati², Ati Zaidah³,
S1 Informatika / Fakultas Ilmu Komputer

Program Studi Informatika, Universitas Pembangunan Nasional Veteran Jakarta
Jl. RS. Fatmawati Raya, Pd. Labu, Kec. Cilandak, Kota Depok, Jawa Barat 12450
email: alfiyahni@upnvj.co.id¹, iinernawati@upnvj.ac.id², zaidiah21@gmail.com³

Abstrak. Pada masa pandemi ini tercipta kebijakan baru dalam dunia pendidikan. Kebijakan tersebut menganjurkan pelajar untuk melaksanakan pembelajaran dalam jaringan (daring) dengan jangka waktu yang panjang. Kebijakan baru menimbulkan banyaknya opini publik yang disampaikan melalui media sosial. Oleh karena itu, penelitian ini akan melakukan analisis sentimen terhadap opini publik mengenai pembelajaran daring di Indonesia untuk memberikan informasi atau evaluasi terhadap opini publik pada media sosial *twitter*. Analisis sentimen dapat dilakukan dengan mengklasifikasi opini publik menjadi opini positif dan opini negatif dengan metode *Support Vector Machine* (SVM). Dalam mengklasifikasikan data dapat dilakukan pelabelan data dan pembersihan data terlebih dahulu sebelum melalui proses *text preprocessing*, kemudian data diberikan bobot setiap kata dengan *Term Frequency-Invers Document Frequency* (TF-IDF) yang akan dijadikan sebagai fitur setelah itu pembagian data menggunakan *10-fold cross validation* dan diklasifikasikan dengan metode *Support Vector Machine* (SVM). Hasil rata-rata evaluasi dengan *confusion matrix* yaitu *accuracy* sebesar 0,72.

Kata Kunci : Analisis Sentimen, Klasifikasi, Pembelajaran Daring, *Support Vector Machine* (SVM).

1 Pendahuluan

Saat ini seluruh dunia termasuk Indonesia sedang terdampak sebuah virus yang mematikan yaitu *Covid-19*. Pada masa pandemi ini mengharuskan semua rakyat di Indonesia untuk menjalankan beberapa kebijakan. Kebijakan – kebijakan tersebut memaksa kita untuk menjalankan kebiasaan baru dalam pencegahan rantai penyebaran virus, salah satunya “dirumah aja”. Hal ini menimbulkan sebuah kebijakan baru dalam dunia pendidikan yaitu pada Surat Edaran yang dikeluarkan Mendikbud Nomor 4 Tahun 2020, mengenai proses BDR (Belajar Dari Rumah) (Kemendikbud 2020, hlm. 1). Kebijakan tersebut menjelaskan tentang pelaksanaan proses Belajar Dari Rumah (BDR) dengan mengubah pembelajaran tatap muka yang biasa dilaksanakan disekolah maupun dikampus dengan pembelajaran secara *online* atau daring (Kemendikbud 2020, hlm. 1). Dengan diundurkannya seluruh pelajar di Indonesia untuk tetap belajar dirumah atau disebut dengan PJJ (Pembelajaran Jarak Jauh) memang bukan hal yang baru untuk dilakukan. Namun untuk waktu jangka panjang dan dilakukan secara bersamaan oleh semua tingkat bawah hingga tingkat atas pelajar Indonesia pembelajaran daring merupakan hal yang baru dilakukan. Dengan adanya perubahan sistem pembelajaran jarak jauh ini, menimbulkan beberapa opini publik yang berupa opini positif, opini netral maupun opini negatif dari berbagai kalangan pelajar di Indonesia.

Dengan adanya opini publik dapat dilakukan analisis sentimen untuk mendapatkan sebuah informasi. Analisis sentimen merupakan penelitian untuk mengenali opini seseorang terhadap suatu kejadian. Analisis sentimen dilakukan dengan mengelompokan/ klasifikasi polaritas apakah pendapat yang terdapat dalam suatu teks maupun dokumen, kalimat bersifat positif, netral maupun negatif [1]. Dalam melakukan klasifikasi pada kumpulan data *tweet* pada media sosial *twitter* harus dilakukan pengolahan teks atau disebut dengan *text mining*. *Text mining* dapat didefinisikan sebagai proses penggalian data berbasis teks yang berkaitan dengan informasi apa yang akan *user* cari serta mencari hubungan atau korelasi yang menarik dengan menggunakan *tools* analisis yang merupakan komponen-komponen dari data mining [2]. Pengolahan teks atau *text mining* dapat dilakukan dengan beberapa tahap dalam *preprocessing* atau pembersihan data teks untuk dapat dilakukan ke tahap klasifikasi berikutnya. Dalam analisis sentimen opini publik dapat diklasifikasikan menjadi opini positif maupun opini negatif agar data dapat menghasilkan sebuah informasi. Algoritma SVM merupakan teknik klasifikasi yang dapat digunakan untuk mengklasifikasikan data. Pada penelitian ini Algoritma klasifikasi yang digunakan adalah metode SVM (*Support Vector Machine*). Dengan dilakukan analisis sentimen dapat pada penelitian ini dapat memberikan hasil berupa

informasi mengenai proses klasifikasi atau hasil klasifikasi yang dapat dijadikan sebagai evaluasi keefektifan mekanisme pelaksanaan proses Belajar Dari Rumah (BDR) menurut pandangan dimasyarakat pada media sosial *Twitter*.

2 Landasan Teori

2.1 Fleiss Kappa

Fleiss kappa merupakan metode yang digunakan untuk mengukur sebuah kesepakatan dalam melakukan penelitian dengan menggunakan dua atau lebih penilai [3]. Berikut merupakan rumus perhitungan kappa:

$$kappa = \frac{p_{\alpha} - p_{\epsilon}}{1 - p_{\epsilon}} \quad (1)$$

Dengan rumus perhitungan presentase jumlah pengukuran antar rater atau (p_{α}) sebagai berikut:

$$p_{\alpha} = \frac{1}{n} \sum_{i=1}^n \frac{\sum_{j=1}^k x_{ij}^2 - m}{m(m-1)} \quad (2)$$

dan rumus perhitungan presentase jumlah perubahan antar rater atau (p_{ϵ}) sebagai berikut:

$$p_{\epsilon} = \sum_{j=1}^k q_j^2, \text{ dimana } q_j \text{ adalah } q_j = \frac{1}{nm} \sum_{i=1}^n x_{ij} \quad (3)$$

Keterangan:

- p_{α} : Presentase jumlah pengukuran antar rater
- p_{ϵ} : Presentase jumlah perubahan antar rater
- n : Jumlah data
- m : Jumlah rater
- x_{ij} : Jumlah keputusan rater

Berikut merupakan tabel interpretasi kappa:

Tabel 1. Interpretasi Kappa

Indeks Kappa	Agreement
1.00 – 0.81	<i>Almost perfect agreement</i>
0.80 – 0.61	<i>Substantial agreement</i>
0.60 – 0.41	<i>Moderate agreement</i>
0.40 – 0.21	<i>Fair agreement</i>
0.20 – 0.00	<i>Slight agreement</i>
<0	<i>Poor agreement or no agreement</i>

Pada Tabel 1 untuk indeks kappa sekitar 0,41 hingga 0,60 kesepakatan dapat dikatakan “*Moderate*” atau sedang, sehingga pada penelitian ini 0,60 dijadikan sebagai batas indeks kappa dalam pelabelan data untuk melanjutkan proses penelitian ketahap berikutnya.

2.2 Text Pre-processing

Pre-prosesing merupakan sebuah tahap awal dalam pengolahan data yang berfungsi untuk membersihkan data sehingga terbentuk sebuah data sesuai kebutuhan untuk dapat diproses lebih lanjut. Data teks yang diperoleh biasanya tidak terstruktur atau data mentah yang memiliki banyak *noise* seperti tanda baca, simbol-simbol, imbuhan, angka dan lain sebagainya [1]. *Text preprocessing* bertujuan untuk mengubah suatu data teks yang tidak terstruktur menjadi sebuah data teks yang terstruktur. Dalam melakukan *text preprocessing* perlu dilakukannya beberapa tahap agar data menjadi sebuah data teks yang terstruktur, Berikut merupakan tahapan *text preprocessing*:

- a. *Normalization*, merupakan proses perbaikan kata-kata yang salah eja atau disingkat dalam bentuk tertentu. Pada tahap *normalization* ini bertujuan untuk memperkecil dimensi kata yang memiliki arti sama tetapi memiliki ejaan yang salah [4].
- b. *Case Folding*, merupakan tahapan untuk mengubah bentuk kata menjadi sama dengan melakukan perubahan huruf kapital (*uppercase*) menjadi huruf kecil (*lowercase*) [5].
- c. *Data Cleaning*, merupakan tahapan yang digunakan untuk menghapus karakter yang telah ditentukan. Karakter yang dihapus seperti *username*, *hashtag* dan url dari situs web [6].

- d. *Stopword Removal*, merupakan tahapan untuk membuang kata-kata yang tidak dibutuhkan. Dalam melakukan proses ini diperlukanya algoritma *stoplist* (menghapus kata yang tidak penting) atau *wordlist* (menyimpan kata yang penting) [1].
- e. *Stemming*, merupakan tahapan untuk mentransformasi kata-kata yang terdapat dalam suatu dokumen menjadi sebuah kata dasar (*root word*) dengan menggunakan aturan aturan tertentu [7].
- f. *Tokenizing*, merupakan tahapan untuk memotong string input satuan kata penyusunnya [8]. Pemecahan kalimat menjadi kata-kata tunggal dilakukan dengan menganalisis kalimat dengan kalimat pemisah (*delimiter*) *whitespace* (spasi, tab, dan *newline*) [9].

2.3 Term Frequency-Inverse Document Frequency (TF-IDF)

Pembobotan kata ini bertujuan untuk mengetahui seberapa besar diperlukan suatu kata untuk mewakili sebuah kalimat, sehingga diperlukanya sebuah perhitungan dan pembobotan kata untuk mengetahui tingkat dibutuhkan suatu kata. [6]. *Term Frequency-Inverse Document Frequency* (TF-IDF) merupakan metode dalam pembobotan kata dengan mengintegrasikan *tf* (*term frequency*) dan *idf* (*inverse document frequency*).

Tahapan dalam pembobotan kata yaitu:

1. Term Frequency (tf)

Term Frequency merupakan jumlah banyak kata yang muncul dalam suatu dokumen. Sedangkan w_{tf} merupakan bobot dari *tf* yang dihitung dengan algoritma.

$$w_{tf,t,d} = \begin{cases} 1 + \log_{10}(tf_{t,d}), & \text{if } tf_{t,d} > 0 \\ 0 & \text{if } tf_{t,d} = 0 \end{cases} \quad (4)$$

2. Inverse Document Frequency (idf)

Document frequency atau disebut juga dengan *df* merupakan jumlah banyak dokumen yang mengandung suatu kata. Sedangkan *idf* adalah bobot kebalikan dari bobot *document frequency* atau dapat dikatakan jumlah . Semakin besar *idf* maka kata jarang muncul dalam suatu dokumen.

$$idf_t = \log_{10} \left(\frac{N}{df_t} \right) \quad (5)$$

3. Term Frequency - Inverse Document Frequency (TF-IDF)

TF-IDF merupakan pembobotan yang didapatkan dari hasil perkalian dari pembobotan *term frequency* (w_{tf}) dengan *Inverse Document Frequency* (idf_t) dari suatu *term*.

$$w_{t,d} = w_{tf} \times idf_t \quad (6)$$

Keterangan:

$tf_{t,d}$: Jumlah kemunculan *term* (t) pada dokumen (d)

N : Jumlah dokumen teks

df_t : Jumlah dokumen yang mengandung *term* (t)

2.4 Support Vector Machine (SVM)

Dalam membuat model suatu data diperlukanya sebuah algoritma. Salah satu algoritma dalam klasifikasi data adalah SVM (*Support Vector Machine*). *Support Vector Machine* adalah sebuah algoritma klasifikasi yang diperkenalkan oleh Boser, Guyon dan Vapnik pada tahun 1992. SVM *Support Vector Machine* juga dikenal sebagai teknik pembelajaran *machine learning* yang paling mutakhir setelah pembelajaran *Neural Network* [4]. Algoritma SVM merupakan klasifikasi yang memisahkan dua kelas dengan cara melakukan pencarian *hyperplane* terbaik dengan *margin* terbesar dari sampel yang diberikan [10]. *Hyperplane* adalah batas antara dua data yang berdekatan atau memiliki jarak terdekat tetapi berbeda kelas. Dalam pencarian *hyperplane* terbaik harus didapatkan sebuah *margin* terbesar dan mencari titik maksimalnya. *Margin* adalah jarak antara *hyperplane* dan *support vector*. *Support vector* merupakan data yang memiliki jarak terdekat dengan *hyperplane* atau dapat dikatakan data yang sulit untuk diklasifikasi. Nilai *margin* (jarak) antara bidang pembatas dapat dihitung dengan mengurangi jarak antara masing-masing bidang pembatas dengan garis titik pusat koordinat, sehingga dapat dirumuskan berdasarkan persamaan jarak garis ke titik pusat koordinat:

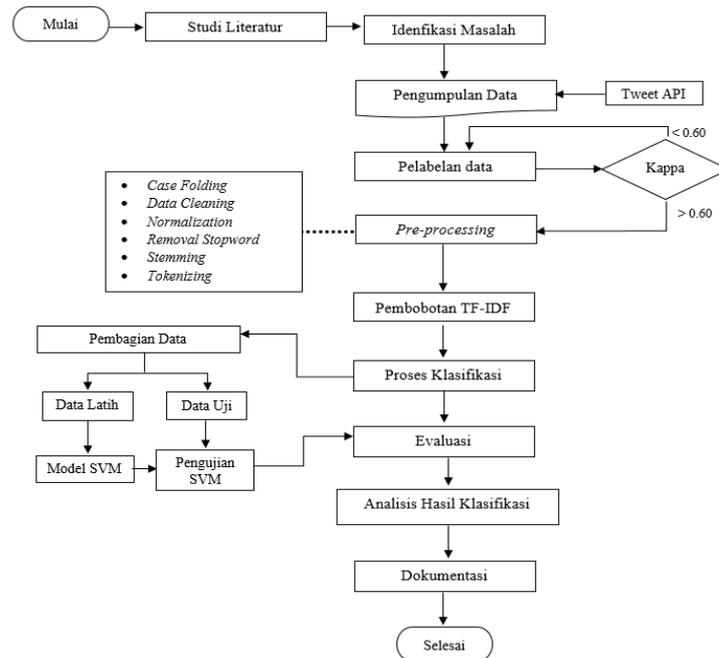
$$\frac{1-b-(-1-b)}{w} = \frac{2}{|w|} = \frac{2}{\sqrt{w_1^2 + w_2^2}} \quad (7)$$

Nilai *margin* dimaksimalkan dengan tetap memenuhi persamaan bidang pembatas kedua kelas. Dengan memaksimalkan nilai $\frac{1}{|w|}$, sama dengan meminimumkan $|w|^2$, sehingga bidang pemisah terbaik dengan *margin* terbesar atau disebut dengan *hyperplane* terbaik dapat dirumuskan menjadi masalah optimasi konstrain yaitu:

$$\min \frac{1}{2} |w|^2 = \min \frac{1}{2} (\sqrt{w_1^2 + w_2^2})^2 = \min \frac{1}{2} (w_1^2 + w_2^2) \quad (8)$$

Dengan syarat $y_i (x_i w + b) - 1 \geq 0$.

3 Metodologi Penelitian



Gambar 1. merupakan ilustrasi alur penelitian yang telah dilakukan. Pada Gambar 1 tersebut terdapat beberapa langkah penelitian. Berikut merupakan penjelasan alur penelitian yang telah dilakukan.

1. **Identifikasi Masalah**, Identifikasi masalah merupakan pengenalan masalah dalam penelitian yang akan dilakukan.
2. **Studi Literatur**, Studi literatur dalam penelitian ini dilakukan sebagai sumber pustaka dengan mengumpulkan buku-buku, jurnal terkait mengenai analisis sentimen, *text mining*, *pre-processing* dan algoritma klasifikasi *Support Vector Machine* yang dibahas dalam penelitian dan sebagainya.
3. **Pengumpulan Data**, Data yang digunakan dalam penelitian ini berupa opini publik pada media sosial *twitter* atau disebut juga dengan *tweet* yang mengandung kata “kelas *online*” dan “kelas *daring*”. Dalam pengumpulan data *tweet* ini, media sosial *twitter* sudah menyediakan API (*Application Programming Interface*) sebagai akses dalam pengambilan data pada *twitter*.
4. **Pelabelan Data**, Pada penelitian ini akan disepakati bahwa sentimen positif adalah opini publik yang mengandung kesenangan, kepuasan, dan semangat. Sedangkan sentimen negatif adalah opini publik yang mengandung kekecewaan dan keluhan. Pelabelan data *tweet* dilakukan secara manual dengan menggunakan tiga orang sebagai anatator yang akan melabelkan data *tweets* yang akan dianalisis. Pelabelan akan disepakati menggunakan pengukuran tingkat kesepakatan antar anatator dengan *tools fleiss Kappa* yang sudah dijelaskan pada bab sebelumnya dengan batas reabilitas untuk hasil pengamatan yang baik sebesar 0,6 – 07 menggunakan rumus (1), (2) dan (3) .
5. **Pre-Processing**, Berikut merupakan langkah *pre-processing* :
 - a. **Case Folding**, Tahapan *case folding* akan dilakukan dengan mengubah data yang menggunakan huruf kapital (*uppercase*) menjadi huruf kecil (*lowercase*). Seperti “BeLajar” menjadi “belajar”
 - b. **Data Cleaning**, Berikut merupakan tahapan proses *data cleaning* pada penelitian ini:
 1. Mengubah *emoticon* menjadi sebuah kata yang memiliki arti sama,
 2. Menghapus *link* ,

3. Menghapus *Username* dan *Hashtag* dengan sebuah kata yang diawali @ dan #,
 4. Menghapus beberapa *spasi* menjadi satu *spasi*,
 5. Menghapus pengulangan huruf lebih dari dua menjadi dua huruf. seperti kata “*funnnny*” menjadi “*funny*”,
 6. Menghapus simbol atau angka selain alphabet a-z,
 7. Menghapus “enter” atau “\n” menjadi spasi(“ ”).
- c. **Normalizatin**, Pada penelitian ini dibuat kamus kata untuk proses normalisasi yang berisi daftar kata yang akan dinormalisasikan. Kamus kata pada proses normalisasi penelitian ini berisi sebanyak 1147 kata.
 - d. **Stopword Removal**, Penghapusan kata *stopword* akan dilakukan dengan menggunakan daftar *stopword* pada *library* sastrawi. Pada *library* sastrawi berisikan daftar *stopword* dalam bahasa indonesia yang berisi sebanyak 809 kata.
 - e. **Stemming**, Pada proses ini penghapusan imbuhan menggunakan aturan yang dilakukan oleh sastrawi pada *library* sastrawi. Misalnya kata “belajar” menjadi “ajar”.
 - f. **Tokenizing**, Pada tahap *tokenizing* dilakukan dengan memotong kata pada suatu *tweet* menjadi satuan kata penyusunnya. Pada penelitian ini terdapat sebanyak 1882 kata dalam 700 data *tweet* yang digunakan.
6. **Pembobotan TF-IDF**, Pada tahap pembobotan ini dilakukan perhitungan untuk memberikan nilai atau bobot kata dalam setiap dokumen untuk dapat membantu klasifikasi data. Pada pembobotan ini diperlukan nilai tf, df dan idf. Tahap awal pembobotan data dapat dilakukan perhitungan tf untuk setiap term pada dokumen dengan menggunakan rumus (4). Kemudian dilakukan perhitungan idf dengan menggunakan rumus (5). Hasil akhir pembobotan tf-idf ini merupakan hasil perkalian nilai tf dan idf dengan menggunakan rumus (6).
 7. **Klasifikasi Data**, Dalam mengklasifikasikan data diperlukanya pembentukan model dan implementasi model. Sebelum melakukan pembentukan model data akan dibagi menjadi dua jenis yaitu data latih dan data uji dengan menggunakan metode *10 - fold cross validation*. Pembentukan model akan dilakukan dengan menggunakan data latih yang sudah diberi label dan model dibentuk menggunakan algoritma SVM dengan melakukan pencarian hyperplane terbaik menggunakan rumus (8). Setelah pembentukan model, model akan diimplementasikan dengan mengklasifikasikan data uji yang tidak berlabel dengan menggunakan algoritma SVM dengan melakukan prediksi.
 8. **Evaluasi**, Tahap evaluasi dilakukan dengan menggunakan metode *confusion matrix*. Evaluasi dilakukan untuk mengetahui tingkat kebenaran dalam pembangunan dan pembentukan model dengan memberikan nilai evaluasi berupa presentase dari akurasi (*accuracy*), sensitifitas (*recall*) pada sentimen positif dan sentimen negatif, nilai *precision* pada sentimen positif dan sentimen negatif, *F-Measure* pada sentimen positif dan sentimen negatif .
 9. **Analisis Hasil Klasifikasi**, Analisis hasil klasifikasi dapat dilakukan dengan menampilkan visualisasi. Visualisasi dapat di tampilkan dalam bentuk diagram, *word cloud*, tabel dan lain lain.
 10. **Dokumentasi**, Dokumentasi akan dilakukan selama proses penelitian berlangsung. Dokumentasi dapat digunakan sebagai acuan penelitian selanjutnya dalam melakukan penelitian atau dapat dikembangkan kembali.

4 Hasil dan Pembahasan

Pada penelitian ini dilakukan pengumpulan data melalui Media sosial *twitter* telah menyediakan *website developer.twitter.com* yang dapat diakses untuk mendapatkan sebuah API *twitter*. *Website developer.twitter.com* akan memberikan API *key*, API *secret*, *Access Token*, *Access Token Secret* untuk dapat mengakses API *twitter*. Pengambilan data dilakukan menggunakan perangkat lunak *google colab* dengan bahasa pemrograman *python* dan menggunakan *library tweepy*. Sebanyak 1257 data yang telah didapat dalam rentang waktu 18-02-2021 sampai 25-02-2021 dengan menggunakan kata kunci “*kelas online*” dan “*kelas daring*”. Setelah pengumpulan data, data akan melalui proses penyaringan karena masih banyaknya data yang tidak berkaitan dengan pembelajaran daring di Indonesia salah satunya seperti iklan, sehingga didata didapat sebanyak 804 data yang digunakan untuk proses selanjutnya yaitu pelabelan data. Setelah dilakukan pelabelan data oleh tiga anator, data yang akan digunakan sebanyak 700 data yang terdiri dari 350 negatif dan 350 positif. Hasil pelabelan pada data *tweet* dapat disebut dengan kesepakatan tiga anator. Kesepakatan yang telah dilakukan akan diukur dengan *fleiss kappa* dengan

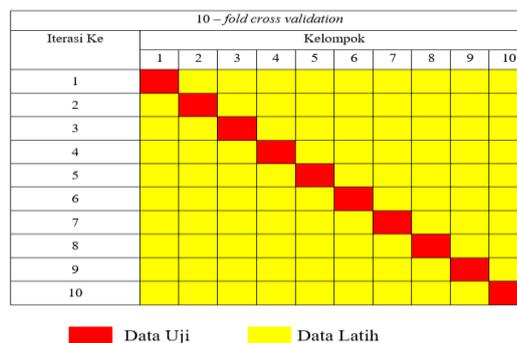
menggunakan rumus (1), (2) dan (3). Perhitungan kappa pada penelitian ini dilakukan dengan menggunakan *microsoft excel* karena data yang digunakan sebanyak 700 data. Hasil perhitungan dengan *microsoft excel* didapat nilai p_α sebesar 0,897143 dan p_ϵ sebesar 0,500016. Berikut merupakan perhitungan kappa dan hasil kappa yang didapat:

$$\text{kappa} = \frac{p_\alpha - p_\epsilon}{1 - p_\epsilon} = \frac{0,897143 - 0,500016}{1 - 0,500016} = \frac{0,397127}{0,499984} = 0,794279$$

Hasil nilai *fleiss kappa* pada 700 data tweet didapat sebesar 0,79427 sehingga masuk dalam kategori *substantial perfect agreement* yang memiliki arti bahwa kesepakatan yang digunakan dalam pelabelan data sudah baik. setelah dilakukan pelabelan data dilakukan pembersihan data melalui *pre-processing*. Berikut merupakan salah satu data *tweet* yang sebelum dan sesudah dilakukan *pre-processing*:

Sebelum Pre-processing	Sesudah pre-processing
@SHidayat2428 @Kemdikbud_RI Gila emang nih. Masa dlm setahun ini gak bisa membuat sistem pembelajaran yg efektif dan efisien pd masa pandemi? Belajar daring tp masih pake metode belajar dlm kelas, setiap hari, dan sama waktunya dgn sekolah biasa, gila bener.	['gila', 'tahun', 'sistem', 'ajar', 'efektif', 'efisien', 'pandemi', 'ajar', 'daring', 'pakai', 'metode', 'ajar', 'kelas', 'sekolah', 'gila']

Setelah melalui *pre-processing* dilakukan pembobotan kata dengan menggunakan TF-IDF. Pada penelitian ini pembobotan TF-IDF akan dilakukan oleh 700 dokumen/tweet. Setelah dilakukan proses perhitungan TF-IDF pada 700 dokumen/*tweets* yang menghasilkan *term* sebanyak 1882 *term*/kata yang sudah memiliki bobot, akan dijadikan sebagai fitur dalam proses klasifikasi data. Setelah proses pembobotan kata, akan dilakukan pembagian data menggunakan *10-fold cross validation* dengan menggunakan 700 dokumen dimana 700 dokumen akan dibagi menjadi 10 kelompok, sehingga setiap kelompok akan terdiri dari 70 dokumen.



Gambar 2. Ilustrasi pembagian data menggunakan 10-fold cross validation. Misalnya pada iterasi pertama kelompok 1 akan dijadikan sebagai data uji dengan jumlah data sebanyak 70 dokumen/*tweet* dan pada kelompok 2,3,4,5,6,7,8,9, dan 10 akan dijadikan data latih dengan jumlah dokumen yang sama pada setiap kelompoknya sebanyak 70 dokumen/*tweet* sehingga data latih berjumlah 630 dokumen pada setiap iterasi. Seperti pada gambar 4.8 setiap iterasi yang dilakukan memiliki data uji yang berbeda, sehingga dengan metode *10-fold cross validation* setiap kelompok atau dokumen akan dijadikan sebagai data uji. Setelah data dibagi kemudian dilakukan pelatihan data pada data latih untuk mendapatkan sebuah bentuk model klasifikasi. Sebelum melakukan pemodelan data dilakukan *Hyperparameter Tunning* dengan menggunakan *Grid Search CV*. Empat kernel yang diujikan yaitu *Linear*, *RBF*, *Sigmoid* dan *Polynomial*. Uji parameter dilakukan dengan menggunakan parameter c yaitu 1, 10, 100, 1000 dan parameter γ yaitu 0.01, 0.1, 1, 10, 100. Uji ini dilakukan dengan menggunakan pembagian data 80:20. Setelah dilakukan uji untuk setiap parameter didapatkan hasil parameter yang terbaik pada setiap kernel. Berikut merupakan hasil parameter yang terbaik pada setiap kernel :

Tabel 2. Hasil Parameter Terbaik *Grid Search CV* setiap kernel

Parameter Terbaik	Kernel			
	Linear	RBF	Poly	Sigmoid
c	1	10	0,1	1000
γ	0,1	0,1	10	0,01

Tabel 2 menunjukan hasil parameter terbaik *Grid Search CV* untuk setiap kernel. Setelah didapatkan parameter terbaik untuk setiap kernel, selanjutnya akan dilakukan implementasi dengan menggunakan parameter terbaik pada tabel 2 untuk setiap kernel. Berikut merupakan hasil akurasi untuk setiap kernel :

Tabel 3. Hasil akurasi parameter terbaik *Grid Search CV*

	Kernel			
	Linear	RBF	Poly	Sigmoid
akurasi	71,4%	70,0%	63,6%	68,5%

Pada tabel 3. nilai akurasi yang lebih tinggi dari metode kernel lainnya adalah dengan menggunakan kernel *linear* dengan hasil akurasi sebesar 71,4% pada parameter $c = 1$ dan $\gamma = 0,1$. Oleh karena itu, penelitian ini akan menggunakan kernel *linear* sebagai parameter untuk pemodelan data pada proses klasifikasi pada data tweet mengenai pembelajaran daring di Indonesia. Dalam penelitian ini pemodelan data dilakukan dengan menggunakan algoritma SVM (*Support Vector Machine*). Pemodelan ini dilakukan dengan menggunakan beberapa *library* pada *python*.

Tabel 4. Hasil Evaluasi

Iterasi ke -	Positif			Negatif			Accuracy
	Precision	Recall	F1-Score	Precision	Recall	F1-Score	
1	0,80	0,85	0,82	0,86	0,85	0,83	0,83
2	0,89	0,70	0,78	0,63	0,85	0,72	0,76
3	0,74	0,76	0,75	0,77	0,75	0,76	0,76
4	0,66	0,82	0,73	0,86	0,71	0,78	0,76
5	0,54	0,54	0,54	0,54	0,54	0,54	0,54
6	0,66	0,72	0,69	0,74	0,68	0,71	0,70
7	0,83	0,81	0,82	0,80	0,82	0,80	0,81
8	0,71	0,66	0,68	0,63	0,71	0,66	0,67
9	0,51	0,60	0,55	0,66	0,57	0,60	0,59
10	0,69	0,80	0,74	0,83	0,72	0,77	0,76

Tabel 4. Merupakan hasil dari evaluasi data *confusion matrix* pada setiap iterasi dengan *10-fold cross validation* menggunakan SVM (*Support Vector Machine*). Dari hasil perhitungan pada tabel 4 dapat dilihat bahwa pada iterasi ke-1 memiliki nilai akurasi tertinggi yang bernilai 0,83 atau 83%. Sedangkan pada iterasi ke-5 memiliki nilai akurasi terendah dengan nilai akurasi sebesar 0,54 atau 54%. Pada tabel 4 dapat dihitung rata-rata dari *Precision*, *Recall*, *F1-Score* dan *Accuracy*. Berikut merupakan hasil dari rata-rata evaluasi data pada *confusion matrix*:

Tabel 5. Hasil rata-rata evaluasi

	Positif			Negatif			accuracy
	precision	recall	f1-score	precision	recall	f1-score	
Rata-Rata	0,703	0,726	0,712	0,732	0,720	0,717	0,717143

Berdasarkan tabel 5. Pada penelitian ini didapatkan rata-rata hasil evaluasi pada tabel 4 dengan *accuracy* sebesar 0,72 atau 72%, nilai *precision* positif sebesar 0,70 atau 70% dan *precision* negatif sebesar 0,73 atau 73% , *recall* positif sebesar 0,73 atau 73% dan *recall* negatif sebesar 0,72 atau 72%, *f1-score* positif sebesar 0,71 atau 71% dan *f1-score* negatif sebesar 0,72 atau 72%. Berikut merupakan visualisasi dalam bentuk *wordcloud* pada sentimen positif dan sentimen negatif:



Gambar 3. *Wordcloud* sentimen (a) positif dan (b) negatif. Pada gambar 3 menunjukkan visualisasi kata terbanyak yang lebih jelas dan lebih luas dalam bentuk wordcloud. Visualisasi pada wordcloud ini menampilkan kata dengan semakin banyak kata yang muncul akan semakin besar dan jelas ukuran kata pada *wordcloud*. Dengan mengetahui banyaknya kata yang sering muncul akan dapat dijadikan sebuah informasi sebagai topik pembahasan yang sering dibahas atau sebagai penilaian pada sentimen positif ataupun negatif dalam pembelajaran daring.

Seperti pada gambar 3 terlihat pada bagian (a) kata positif yang muncul pada tweet seperti kata “semangat”, “santai” dan “kagum”, sedangkan pada bagian (b) kata negatif yang muncul pada tweet seperti kata “susah”, “malas”, “lelah”, “kesal” dan “penat”. Dengan demikian kata-kata tersebut dapat mewakili opini publik terhadap pembelajaran daring di Indonesia.

5 Kesimpulan dan Saran

Pada penelitian ini dapat ditarik kesimpulan, proses klasifikasi dilakukan dengan pelabelan data secara manual pada 700 data tweet yang terdiri dari 350 data berlabel positif dan 350 data berlabel negatif. dengan hasil penelitian didapat menggunakan *10-fold cross validation* dengan iterasi ke-1 memiliki nilai akurasi tertinggi yang bernilai 0,83 atau 83%. Sedangkan pada iterasi ke-5 memiliki nilai akurasi terendah dengan nilai akurasi sebesar 0,54 atau 54%. Dengan hasil evaluasi didapatkan rata-rata hasil *accuracy* sebesar 0,72 atau 72% dengan nilai *precision* positif sebesar 0,70 atau 70% dan *precision* negatif sebesar 0,73 atau 73% , *recall* positif sebesar 0,73 atau 73% dan *recall* negatif sebesar 0,72 atau 72%, *f1-score* positif sebesar 0,71 atau 71% dan *f1-score* negatif sebesar 0,72 atau 72%. Hasil klasifikasi data *tweet* menjadi 340 data dengan sentimen positif dan 360 data sentimen negatif.

Penelitian selanjutnya Meningkatkan performa *pre-processing* pada *normalization* yang bertujuan memperkecil dimensi kata dan melakukan perbandingan model data sehingga dapat terlihat model data yang lebih baik untuk menambah tingkat akurasi.

Referensi

- [1] F. A. Nugraha, N. H. Harai, and R. Habibi, *Analisis Sentimen Terhadap Pembatasan Sosial Menggunakan Deep Learning*. Bandung: Kreatif Industri Nusantara, 2020.
- [2] S. Fauziah, D. N. Sulistyowati, and T. Asra, *Optimasi Algoritma Vector Space Model Dengan Algoritma K-Nearest Neighbour Pada Pencarian Judul Artikel Jurnal*, vol. 15, no. 1. 2019.
- [3] T. R. Nichols, P. M. Wisner, G. Cripe, and L. Gulabchand, “Putting the kappa statistic to use,” *Qual. Assur. J.*, vol. 13, no. 3–4, pp. 57–61, 2010, doi: 10.1002/qaj.481.
- [4] D. Yosmita Praptiwi, “Analisis Sentimen Online Review Pengguna E-Commerce Menggunakan Metode Support Vector Machine Dan Maximum Entropy,” 2018.
- [5] W. A. Luqyana, I. Cholissodin, and R. S. Perdana, “Analisis Sentimen Cyberbullying Pada Komentar Instagram dengan Metode Klasifikasi Support Vector Machine,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput. Univ. Brawijaya*, vol. 2, no. 11, pp. 4704–4713, 2018.
- [6] P. P. A. Arsyia Monica Pravina, Imam Cholissodin, “Analisis Sentimen Tentang Opini Maskapai Penerbangan pada Dokumen Twitter Menggunakan Algoritme Support Vector Machine (SVM),” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 3, no. 3, pp. 2789–2797, 2019, [Online]. Available: <http://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/4793>.
- [7] D. Wahyudi, T. Susyanto, and D. Nugroho, “Implementasi Dan Analisis Algoritma Stemming Nazief & Adriani Dan Porter Pada Dokumen Berbahasa Indonesia,” *J. Ilm. SINUS*, vol. 15, no. 2, pp. 49–56, 2017, doi: 10.30646/sinus.v15i2.305.
- [8] D. S. Indraloka and B. Santosa, “Penerapan Text Mining untuk Melakukan Clustering Data Tweet Shopee Indonesia,” *J. Sains dan Seni ITS*, vol. 6, no. 2, pp. 6–11, 2017, doi: 10.12962/j23373520.v6i2.24419.
- [9] J. Watori, R. Aryanti, A. Junaidi, and A. Yani, “Penggunaan Algoritma Klasifikasi Terhadap Analisa Sentimen Pemindahan Ibukota Dengan Pelabelan Otomatis,” *J. Inform.*, vol. 7, no. 1, pp. 85–90, 2020, doi: 10.31311/ji.v7i1.7528.
- [10] Chapman and Hall/CRC, *The Top Ten Algorithms in Data Mining*. Taylot & francis Group, LLC, 2009.