

# Sentimen Analisis Pengguna *Twitter* Terhadap Kebijakan Merdeka Belajar Menggunakan Algoritma *Naive Bayes*

Herlambang Dwi Prasetyo<sup>1</sup>, Titin Pramiyati<sup>2</sup>, Ika Nurlaili Isnainiyah<sup>3</sup>  
Program Studi S-1 Sistem Informasi / Fakultas Ilmu Komputer  
Universitas Pembangunan Nasional Veteran Jakarta

Jl. RS. Fatmawati, Pondok Labu, Jakarta Selatan, DKI Jakarta, 12450

herlambangdwi.prasetyo@gmail.com<sup>1</sup>, titin.pramiyati@upnvj.ac.id<sup>2</sup>, nurlailika@gmail.com<sup>3</sup>

**Abstrak.** *Twitter* adalah salah satu situs *microblogging* yang memungkinkan penggunaannya untuk menulis tentang berbagai topik dan membahas isu-isu yang terjadi pada saat ini. Hal tersebut dapat digunakan sebagai sumber data untuk menilai sentimen pada *twitter*. Pada awal tahun 2020 Kementerian Pendidikan dan Kebudayaan Republik Indonesia memperkenalkan sebuah program baru bernama Merdeka Belajar, program ini memiliki empat pokok kebijakan diantaranya Ujian Sekolah Berstandar Nasional (USBN), Ujian Nasional (UN), Rencana Pelaksanaan Pembelajaran (RPP), dan Peraturan Penerimaan Peserta Didik Baru (PPDB) Zonasi. Program Merdeka Belajar tidak lepas dari dukungan maupun penolakan dari masyarakat, berbagai pernyataan maupun opini baik dukungan maupun penolakan diekspresikan masyarakat melalui berbagai media, baik media cetak maupun media sosial seperti *twitter*, dalam rangka menganalisis sentimen pada kebijakan Merdeka Belajar berdasarkan opini publik pada *twitter*, penulis menerapkan proses *text mining* menggunakan algoritma *Naive Bayes Classifier* untuk mengklasifikasi sentimen secara otomatis. Penulis menggunakan 180 data *tweet* dengan sentimen terhadap program tersebut. Data tersebut diklasifikasi secara manual menjadi sentimen positif dan negatif. Kemudian data tersebut dibagi menjadi data *training* dan data *testing*. Akurasi yang paling baik didapatkan sebesar 80.55%, dengan nilai *f1 - score* sebesar 89% serta nilai *precision* dan *recall* masing-masing sebesar 81% dan 100% dengan data latih sebesar 80% dan data uji sebesar 20%, serta mayoritas sentimen terhadap kebijakan tersebut adalah positif.

**Kata Kunci:** Analisis Sentimen, *Twitter*, *Naive Bayes*, Merdeka Belajar

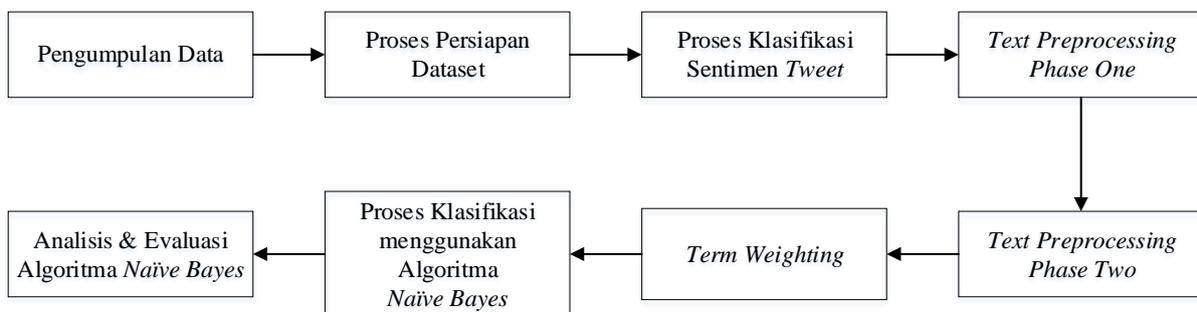
## 1 Pendahuluan

Memasuki era revolusi industri 4.0 pemerintah Indonesia telah membuat berbagai kebijakan baru, Merdeka Belajar merupakan salah satu kebijakan yang dikeluarkan oleh kementerian Pendidikan dan Kebudayaan di awal tahun 2020, dimana dalam program merdeka belajar ini mengandung empat pokok kebijakan utama yaitu, perubahan bentuk dan mutu Ujian Sekolah Berstandar Nasional (USBN), perubahan dalam pembuatan dan perancangan Rencana Pelaksanaan Pembelajaran (RPP), penghapusan Ujian Nasional, dan perbaikan pada sistem peraturan Penerimaan Peserta Didik Baru (PPDB) Zonasi. Usulan Nadiem Makarim mengenai kebijakan Merdeka Belajar memiliki tujuan agar setiap guru dan siswa di Indonesia memiliki makna mengajar dan menuntut ilmu secara merdeka, dimana lembaga pendidikan atau sekolah menjamin baik siswa maupun guru memiliki kebebasan dalam berkarya dengan belajar secara mandiri, menghasilkan inovasi dalam pengajaran, dan berpikir kreatif dalam menghadapi persaingan di era revolusi industri 4.0 [1]. Kebijakan Merdeka Belajar yang digagas oleh Kementerian Pendidikan dan Kebudayaan ini sangat mencuri perhatian rakyat Indonesia karena salah satu program dalam kebijakan Merdeka Belajar yaitu Ujian Nasional, mulai tahun 2021 Ujian Nasional ini resmi ditiadakan setelah berjalan selama puluhan tahun dan diganti menjadi ujian asesmen pendidikan. Menteri Pendidikan dan Kebudayaan Republik Indonesia menjelaskan selain penghapusan Ujian Nasional, ada beberapa poin penting mengenai Merdeka Belajar yang perlu diketahui masyarakat yaitu pertama Ujian Sekolah Berstandar Nasional (USBN) diganti menjadi ujian asesmen yang memberikan keleluasaan bagi sekolah untuk menentukan kelulusan [2], selanjutnya beliau menjelaskan dalam Merdeka Belajar ini yakni Rencana Pelaksanaan Pembelajaran (RPP) yang berisi tujuan dan capaian pembelajaran bagi siswa, kegiatan pengajaran dan pembelajaran, serta asesmen penilaian isinya dipersingkat sehingga saat ini dapat disusun sebanyak RPP satu halaman saja, yang sebelumnya penyusunan RPP dapat mencapai belasan hingga puluhan halaman, yang terakhir adalah regulasi mengenai mekanisme Penerimaan Peserta Didik Baru (PPDB), dimana pada program ini

sistem PPDB zonasi dirancang lebih fleksibel sehingga mengurangi ketimpangan akses dan kualitas pendidikan di berbagai wilayah [2].

Sebuah gagasan tentunya tidak akan pernah terlepas dari dukungan maupun penolakan dari masyarakat, begitupun dengan konsep Program Merdeka Belajar yang digagas oleh Nadiem Makarim tidak akan pernah lepas dari dukungan maupun penolakan dalam masyarakat. Pihak yang mendukung kebijakan ini menilai bahwa program ini merupakan solusi untuk memajukan pendidikan di Indonesia, sedangkan pihak yang menolak gagasan ini menilai bahwa dengan penghapusan Ujian Nasional yang menjadi salah satu poin Merdeka Belajar dapat menurunkan motivasi siswa dalam belajar. Berbagai pernyataan maupun opini baik dukungan maupun penolakan lain diekspresikan masyarakat melalui berbagai media, baik media cetak maupun media sosial seperti *twitter* dalam rangka menilai kebijakan Merdeka Belajar berdasarkan opini publik pada *twitter*, dengan latar belakang tersebut, menjadikan penulis termotivasi untuk melakukan penelitian terhadap pengukuran sentimen analisis pengguna *twitter* terhadap kebijakan merdeka belajar menggunakan metode *text mining*.

## 2 Metode Penelitian



**Gambar. 1.** Alur Tahapan Penelitian

Kegiatan penelitian dimulai dari mengumpulkan data, pengumpulan data dilakukan dengan melakukan *scraping tweet* pada *twitter* menggunakan *twitter scraper*, dilanjutkan dengan proses perisapan data serta melakukan klasifikasi sentimen pada *tweet*, melakukan *text preprocessing phase one*, dilanjutkan *text preprocessing phase two*, melakukan pembobotan kata, proses klasifikasi menggunakan algoritma *Naive Bayes*, dan yang terakhir menganalisis mengevaluasi algoritma *Naive Bayes*.

## 3 Proses Pemodelan

### 3.1 Pengumpulan Data

Pengumpulan data pada penelitian ini dilakukan menggunakan proses *scraping* menggunakan bahasa pemrograman python dengan menggunakan library *twitter scraper*, data yang diambil merupakan *tweet* yang berasal dari bulan Januari hingga bulan Februari 2020. Output dari proses ini adalah dataset yang tersimpan dalam bentuk CSV. Pada tahap ini terkumpul 869 buah *tweet* yang mengandung kata '#merdekabelajar'.

### 3.2 Proses Persiapan Dataset

1. Seleksi Fitur  
 Dari beberapa fitur yang tersedia hanya dipilih satu fitur seleksi yaitu *text*, karena pada *text* ini terdapat kalimat yang mengindikasikan apakah kalimat itu berisi dukungan atau penolakan. Terdapat satu kelas yaitu label yang dalam hal ini bertindak sebagai target berisi pengklasifikasian *tweet* yang bernilai positif dan negatif.
2. Menghilangkan Duplikasi  
 Pada proses ini *tweet* yang memiliki duplikasi tersebut dapat dihilangkan hingga hanya menyisakan satu *tweet* saja. Metode penghapusannya adalah menggunakan rapidminer dengan operator 'remove duplicates' dimana operator ini akan mengambil *tweet* yang paling akhir berdasarkan urutan baris pada sistem [3].
3. Seleksi *Tweet*  
 Tidak semua isi *text* dari *tweet* menggambarkan dukungan maupun penolakan pada kebijakan Merdeka Belajar, setelah melalui proses *remove duplicates*, masing-masing dari isi *tweet* harus di *screening* guna menentukan apakah *text* tersebut layak atau tidak menjadi bagian dari dataset. Banyak sekali *tweet* yang berisi iklan, pemberitahuan, dan sebagainya yang tentunya hal ini tidak merepresentasikan dukungan maupun penolakan, sehingga *tweet* tersebut perlu dihilangkan. Setelah melalui proses persiapan dataset hanya terdapat 180 *tweet* yang layak untuk masuk ke tahapan selanjutnya

### 3.3 Proses Melabelkan *Tweet*

Pemberian label dilakukan oleh tiga orang berbeda guna menghindari subjektivitas dari pemberian label dalam *tweet*.

**Tabel 1.** Hasil Klasifikasi Sentimen pada *Tweet*

<i>Text</i>	<i>User 1</i>	<i>User 2</i>	<i>User 3</i>	<i>Final Result</i>
Ketidakmerataan guru di sekolah negeri maupun swasta jadi masalah lain dalam dunia pendidikan Indonesia. Dari program #MerdekaBelajar Mendikbud Nadiem makarim, solusi apa saja yang ditawarkan?	Negatif	Negatif	Positif	<b>Negatif</b>
Selengkapnya di #LiputanKhusus #CNNIndonesia berikut ini: <a href="https://bit.ly/39CFuOh">https://bit.ly/39CFuOh</a> <a href="https://pic.twitter.com/14Prx5sW6W">pic.twitter.com/14Prx5sW6W</a>				
Belajar itu bukan sekolah, belajar itu mencari ilmu. Ilmu bisa apa saja, dan kebanyakan ilmu yang penting tidak di ajarkan di sekolah. #hanyaberpendapat #MerdekaBelajar #sekolah	Negatif	Positif	Positif	<b>Positif</b>

### 3.4 Text Preprocessing Phase 1 (Remove Impurities in Text)

1. Menghilangkan *Link* yang Tersema pada *Tweet*  
 Pada tahap ini *link* seperti (<http://www.situs.com>) dan email ([nama@situs.com](mailto:nama@situs.com)) yang tersema pada *tweet* akan dihilangkan.
2. Menghilangkan Nama Pengguna  
*Username* seperti (@namapengguna) akan dihilangkan pada tahap ini.
3. Konversi Emoticon  
 Tabel dibawah merupakan contoh dari beberapa *emoticon* yang kemudian dikonversi nilainya menjadi sedih atau senang, dimana senang mewakili sentimen positif, dan sedih mewakili sentimen negatif.

**Tabel 2.** Tabel Konversi Emoticon

Emoticon	Konversi
:(('[:[:(:/:)x(--':#:-@:c:f;(v:x:s)"): * *	Sedih
:):] (^_^) ^^v^^ ^ ^ 0: <; } :* (^.^) =)	Senang

4. Menghilangkan Tanda Baca  
 Berbagai tanda baca maupun simbol-simbol yang bukan karakter huruf dalam *tweet* akan dihapus pada tahap ini.
5. Menghilangkan Kata yang Tidak Bermakna  
 Kata yang tersusun kurang dari tiga huruf akan dihapus pada proses ini karena dianggap tidak memiliki arti.
6. Menghilangkan Kata Kunci Pencarian  
 Kata 'merdekaelajar' yang menjadi kata kunci pengumpulan dataset akan dihapus pada proses ini.

### 3.5 Text Preprocessing Phase 2 (Extraction and Transformation)

1. *Case folding*  
 Peran *case folding* yang paling utama adalah menyeragamkan kata dalam *text* menjadi huruf kecil [4]. Proses *case folding* pada penelitian menggunakan parameter *transform to 'lower case'* pada *rapidminer*. Hasil dari proses penyeragaman kata kedalam huruf kecil dapat dilihat pada tabel 3 sebagai berikut:

**Tabel 3.** Contoh Hasil *Tweet* setelah Proses *Case folding*

Sebelum	Sesudah
Ketidakerataan guru di sekolah negeri maupun swasta jadi masalah lain dalam dunia pendidikan Indonesia. Dari program Mendikbud Nadiem makarim, solusi apa saja yang ditawarkan	ketidakerataan guru di sekolah negeri maupun swasta jadi masalah lain dalam dunia pendidikan indonesia. dari program mendikbud nadiem makarim, solusi apa saja yang ditawarkan

2. *Tokenization*  
 Setelah melalui proses tokenisasi kalimat akan dipecah menjadi satuan kata dan karakter *non*-abjad dan angka yang tidak termasuk dalam karakter huruf dalam proses ini akan dihilangkan [5].

**Tabel 4.** Contoh Hasil *Tweet* setelah Proses Tokenisasi

Sebelum	Sesudah
ketidakerataan guru di sekolah negeri maupun swasta jadi masalah lain dalam dunia pendidikan indonesia. dari program mendikbud nadiem makarim, solusi apa saja yang ditawarkan	ketidakerataan guru di sekolah negeri maupun swasta jadi masalah lain dalam dunia pendidikan indonesia dari program mendikbud nadiem makarim solusi apa saja yang ditawarkan

### 3. Stemming

Proses stemming adalah proses transformasi dari semua kata yang mendapatkan imbuhan baik diawal maupun diakhir menjadi kata dasar [5]. Proses *stemming* dalam *rapidminer* dapat menggunakan operator '*stem*' dan diaksimalkan menggunakan python.

**Tabel 5.** Contoh Hasil *Tweet* setelah Proses *Stemming*

Sebelum	Sesudah
ketidakmerataan guru di sekolah negeri maupun swasta jadi masalah lain dalam dunia pendidikan indonesia dari program mendikbud nadiem makarim solusi apa saja yang ditawarkan	ketidakmerataan guru di sekolah negeri maupun swasta jadi masalah lain dalam dunia didik indonesia dari program mendikbud nadiem makarim solusi apa saja yang tawar

### 4. Stopwords Removal

Membuang kata yang tidak penting yang didominasi oleh kata hubung seperti 'dan', 'yang', 'itu' atau menyimpan kata penting dan mengambil kata-kata penting dari hasil token merupakan proses utama dalam tahap *filtering* [6].

**Tabel 6.** Contoh Hasil *Tweet* setelah Proses *Removal Stopword*

Sebelum	Sesudah
ketidakmerataan guru di sekolah negeri maupun swasta jadi masalah lain dalam dunia didik indonesia dari program mendikbud nadiem makarim solusi apa saja yang tawar	ketidakmerataan guru sekolah negeri swasta didik indonesia program mendikbud nadiem makarim solusi tawar

## 3.6 Term Weighting

Data yang telah melalui tahap preprocessing harus berbentuk numerik, untuk mengubah data tersebut menjadi numerik yaitu menggunakan metode pembobotan TF-IDF [7].

Perumusan TF

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

Perumusan IDF

$$IDF = \log\left(\frac{N}{df_t}\right) \quad (2)$$

Perumusan TF-IDF

$$W_{t,d} = TF \times IDF \quad (3)$$

### 3.7 Pemodelan Menggunakan Algoritma *Naïve Bayes*

Proses ini menggunakan *python* versi 3.8.5, dataset yang sebelumnya dibagi menjadi 3 uji rangkaian yang masing-masing menggunakan data latih 70% dan data uji 30%, data latih 80% dan data uji 20%, serta data latih 90% dan data uji 10%.

**Tabel 7.** Persentase Pembagian Dataset untuk Pemodelan

Persentase Data Latih	Persentase Data Uji	Jumlah Data Latih	Jumlah Data Uji	Total
70%	30%	126	54	180
80%	20%	144	36	180
90%	10%	162	18	180

## 4 Hasil dan Pembahasan

### 4.1 Analisis dan Evaluasi menggunakan Data Latih 70% dan Data Uji 30%

**Tabel 8.** Hasil *Confusion Matrix* Data Latih sebesar 70% dan Data Uji sebesar 30%

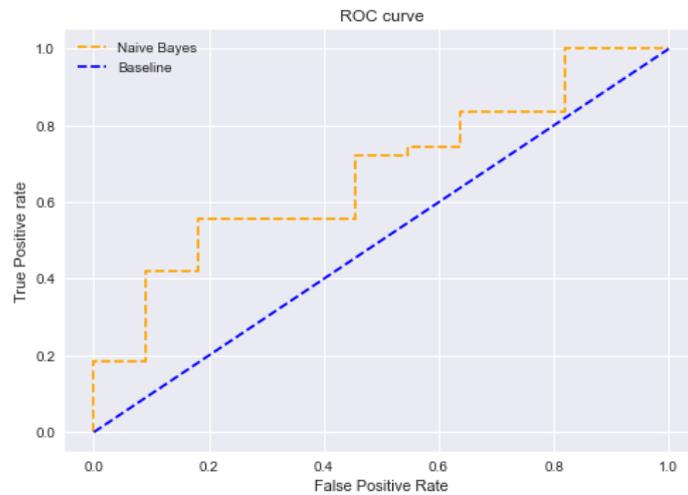
<i>Actual</i>	<i>Prediction</i>	
	Negatif	Positif
Negatif	0	11
Positif	0	43

Nilai akurasi yang didapatkan dari pemodelan dengan data latih 70% dan data uji 30% adalah 79.62 %, hal ini berarti nilai yang dihasilkan dari perbandingan data, atau yang diidentifikasi apakah benar merupakan kelas positif atau kelas negatif dari total keseluruhan data memiliki persentase yang cukup baik sebesar 79.62 %, karena dataset memiliki jumlah kelas yang *imbalance*, kinerja dari algoritma perlu dilihat nilai dari *f1 - score* yang telah dihasilkan, Nilai *f1 - score* yang didapatkan dari pemodelan dengan data latih 70% dan data uji 30% adalah 89% yang artinya kinerja dari algoritma yang telah diterapkan memiliki kemampuan atau kinerja yang baik.

**Tabel 9.** Hasil Performansi Data Latih sebesar 70% dan Data Uji sebesar 30%

	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
Negatif	0.00	0.00	0.00
Positif	0.80	1.00	0.89

Hasil performansi yang ditampilkan menunjukkan tingkat akurasi antara informasi yang diperlukan dengan jawaban yang disediakan oleh sistem menghasilkan nilai sebesar 80% yang artinya sistem memiliki tingkat akurasi yang baik. Kesuksesan dari sistem dalam mendapatkan kembali sebuah informasi memiliki nilai persentase yang sangat tinggi yaitu 100%. Dengan hasil dari nilai *precision* dan *recall* yang sangat tinggi dapat dikatakan bahwa pada pengujian sistem, kualitas klasifikasi yang dihasilkan dari sistem adalah berhasil.



**Gambar. 2.** Grafik ROC Data Latih 70% dan Data Uji 30%

Dapat dilihat bahwa grafik ROC *Naïve Bayes* terhadap pemodelan secara umum dikategorikan ke dalam klasifikasi yang bersifat sangat rendah, karena kurva yang dibentuk oleh algoritma *Naïve Bayes* berpotongan dengan garis *baseline* sehingga dapat disimpulkan bahwa algoritma *Naïve Bayes* yang telah diterapkan memiliki kinerja yang kurang baik. Nilai *Area Under Curve* (AUC) yang merepresentasikan rata-rata sensitivitas untuk semua nilai spesifitas yang mungkin dari pemodelan tersebut menunjukkan *score* 0.6744, dengan hasil nilai tersebut algoritma yang telah diterapkan memiliki kinerja *poor classification*.

#### 4.2 Analisis dan Evaluasi menggunakan Data Latih 80% dan Data Uji 20%

**Tabel 10.** Hasil *Confusion Matrix* Data Latih sebesar 80% dan Data Uji sebesar 20%

Actual	Prediction	
	Negatif	Positif
Negatif	0	7
Positif	0	29

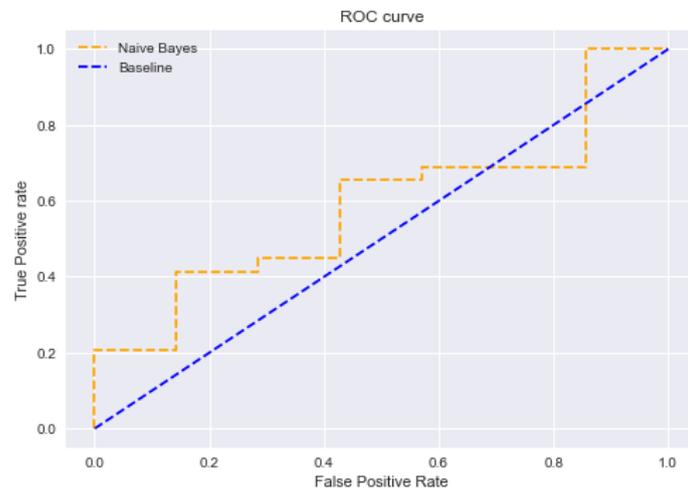
Nilai akurasi yang didapatkan dari pemodelan dengan data latih 80% dan data uji 20% adalah 80.55 %, hal ini berarti nilai yang dihasilkan dari perbandingan data, atau yang diidentifikasi apakah benar merupakan kelas positif atau kelas negatif dari total keseluruhan data memiliki persentase yang cukup baik sebesar 80.55 %, karena dataset memiliki jumlah kelas yang *imbalance*, kinerja dari algoritma perlu dilihat nilai dari *f1 - score* yang telah dihasilkan, Nilai *f1 - score* yang didapatkan dari pemodelan dengan data latih 80% dan data uji 20% adalah 89% yang artinya kinerja dari algoritma yang telah diterapkan memiliki kemampuan atau kinerja yang baik.

**Tabel 11.** Hasil Performansi Data Latih 80% dan Data Uji 20%

	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
Negatif	0.00	0.00	0.00
Positif	0.81	1.00	0.89

Hasil performansi yang ditampilkan menunjukkan tingkat akurasi antara informasi yang diperlukan dengan jawaban yang disediakan oleh sistem menghasilkan nilai sebesar 81% yang artinya sistem memiliki tingkat

akurasi yang baik. Kesuksesan dari sistem dalam mendapatkan kembali sebuah informasi memiliki nilai persentase yang sangat tinggi yaitu 100%. Dengan hasil dari nilai *precision* dan *recall* yang sangat tinggi dapat dikatakan bahwa pada pengujian sistem, kualitas klasifikasi yang dihasilkan dari sistem adalah berhasil.



**Gambar. 3.** Grafik ROC Data Latih 80% dan Data Uji 20%

Dapat dilihat bahwa grafik ROC *Naïve Bayes* terhadap pemodelan secara umum dikategorikan ke dalam klasifikasi yang bersifat sangat rendah, karena kurva yang dibentuk oleh algoritma *Naïve Bayes* berpotongan dengan garis *baseline* sehingga dapat disimpulkan bahwa algoritma *Naïve Bayes* yang telah diterapkan memiliki kinerja yang kurang baik. Nilai *Area Under Curve* (AUC) yang merepresentasikan rata-rata sensitivitas untuk semua nilai spesifitas yang mungkin dari pemodelan tersebut menunjukkan *score* 0.5862, dengan hasil nilai tersebut algoritma yang telah diterapkan memiliki kinerja *fair classification*.

#### 4.3 Analisis dan Evaluasi menggunakan Data Latih 90% dan Data Uji 10%

**Tabel 12.** Hasil *Confusion Matrix* Data Latih 90% dan Data Uji 10%

Actual	Prediction	
	Negatif	Positif
Negatif	0	4
Positif	0	14

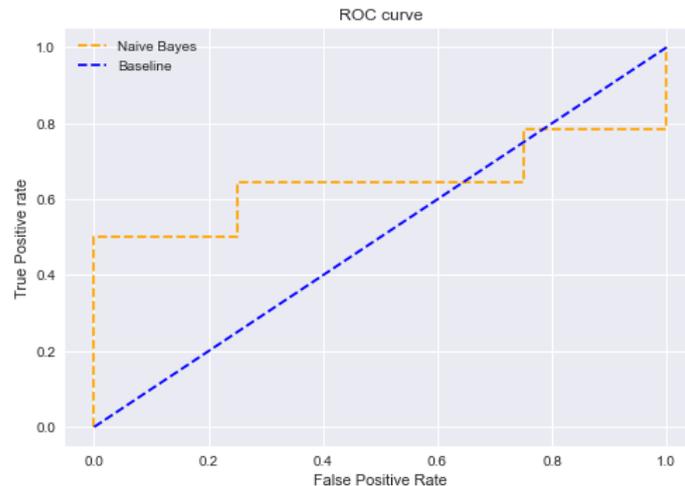
Nilai akurasi yang didapatkan dari pemodelan dengan data latih 90% dan data uji 10% adalah 77.77%, hal ini berarti nilai yang dihasilkan dari perbandingan data, atau yang diidentifikasi apakah benar merupakan kelas positif atau kelas negatif dari total keseluruhan data memiliki persentase yang cukup baik sebesar 77.77 %, karena dataset memiliki jumlah kelas yang *imbalance*, kinerja dari algoritma perlu dilihat nilai dari *f1 - score* yang telah dihasilkan, Nilai *f1 - score* yang didapatkan dari pemodelan dengan data latih 90% dan data uji 10% adalah 88% yang artinya kinerja dari algoritma yang telah diterapkan memiliki kemampuan atau kinerja yang baik

**Tabel 13.** Hasil Performansi Data Latih 90% dan Data Uji 10%

	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
Negatif	0.00	0.00	0.00

Positif	0.78	1.00	0.88
---------	------	------	------

Hasil performansi yang ditampilkan menunjukkan tingkat akurasi antara informasi yang diperlukan dengan jawaban yang disediakan oleh sistem menghasilkan nilai sebesar 78% yang artinya sistem memiliki tingkat akurasi yang baik. Kesuksesan dari sistem dalam mendapatkan kembali sebuah informasi memiliki nilai persentase yang sangat tinggi yaitu 100%. Dengan hasil dari nilai *precision* dan *recall* yang sangat tinggi dapat dikatakan bahwa pada pengujian sistem, kualitas klasifikasi yang dihasilkan dari sistem adalah berhasil.



**Gambar. 4.** Grafik ROC Data Latih 90% dan Data Uji 10%

Dapat dilihat bahwa grafik ROC *Naïve Bayes* terhadap pemodelan secara umum dikategorikan ke dalam klasifikasi yang bersifat sangat rendah, karena kurva yang dibentuk oleh algoritma *Naïve Bayes* berpotongan dengan garis *baseline* sehingga dapat disimpulkan bahwa algoritma *Naïve Bayes* yang telah diterapkan memiliki kinerja yang kurang baik. Nilai *Area Under Curve* (AUC) yang merepresentasikan rata-rata sensitivitas untuk semua nilai spesifitas yang mungkin dari pemodelan tersebut menunjukkan *score* 0.6428, dengan hasil nilai tersebut algoritma yang telah diterapkan memiliki kinerja *poor classification*.

## 5 Kesimpulan dan Saran

### 5.1 Kesimpulan

Berdasarkan analisis dan pengujian yang dilakukan pada bab sebelumnya, maka kesimpulan yang dapat diambil adalah sebagai berikut:

1. Berdasarkan dataset pengguna *twitter* terhadap kebijakan merdeka belajar yang telah diambil sejak Bulan Januari hingga Bulan Februari 2020, menunjukkan bahwa mayoritas pengguna *twitter* tersebut memberikan dukungan terhadap kebijakan merdeka belajar yang telah diterbitkan oleh pemerintah.
2. Algoritma *Naïve Bayes* dapat mengklasifikasikan sentimen dengan nilai akurasi dengan nilai paling baik sebesar 80.55% yang dihasilkan dari data latih sebesar 80% dan data uji sebesar 20%.
3. Performansi dari algoritma *Naïve Bayes* yang dihasilkan dari data latih sebesar 80% dan data uji sebesar 20% juga menunjukkan hasil yang sangat baik. Hal ini dibuktikan dengan nilai dari *precision* adalah 0.81, nilai dari *recall* adalah 1.00, dan nilai *f1-score* adalah 0.89. Namun sayangnya grafik perbandingan yang ditunjukkan oleh kurva *Receiver Operating Characteristic* (ROC) dari dataset

tersebut menunjukkan kinerja yang rendah, karena kurva berpotongan dengan garis *base line* serta nilai yang diberikan oleh *Area Under Curve* (AUC) adalah 0.5862, dimana score model tersebut merepresentasikan *failure classification*.

## 5.2 Saran

Penulis menyarankan pengembangan penelitian lebih lanjut sistem pengklasifikasian *Tweet* sebagai berikut:

1. Pada penelitian selanjutnya diharapkan mampu menggunakan dataset yang lebih banyak, sehingga pembelajaran model dapat lebih baik, sehingga menghasilkan prediksi kelas yang juga baik.
2. Pada penelitian selanjutnya diharapkan mampu menggunakan dataset dengan jumlah kelas yang seimbang, sehingga dapat menggunakan nilai akurasi sebagai tolak ukur kinerja algoritma dan grafik ROC-AUC dapat memberikan representasi klasifikasi yang lebih baik.
3. Pada penelitian selanjutnya dapat menggunakan metode klasifikasi dan seleksi fitur yang lebih baik, seperti penggunaan *Part of Speech Tagging* untuk mengetahui posisi sebuah kata dalam kalimat.
4. Bahasa yang digunakan juga tidak hanya bahasa Indonesia tetapi dapat menggunakan bahasa daerah atau bahasa asing seperti bahasa Inggris dan bahasa asing lainnya.
5. Pada penelitian selanjutnya dapat membandingkan dengan algoritma klasifikasi lain seperti *Support Vector Machine*, *K-NN*, *Decision Tree*, dan sebagainya.

## Referensi

- [1] H. Aesthetic, "Merdeka Belajar, Begini Penjelasan Nadiem," *www.kompasiana.com*, 2019. <https://www.kompasiana.com/humanioraesthetic/5ddd2e98d541df5d6f3eae52/merdeka-belajar-begini-penjelasan-nadiem> (accessed Apr. 06, 2020).
- [2] A. Adit, "Gebrakan 'Merdeka Belajar', Berikut 4 Penjelasan Mendikbud Nadiem," *www.kompas.com*, 2019. <https://edukasi.kompas.com/read/2019/12/12/12591771/gebrakan-merdeka-belajar-berikut-4-penjelasan-mendikbud-nadiem?page=all> (accessed Apr. 04, 2020).
- [3] N. A. Vidya, "Twitter Sentiment Analysis Terhadap Brand RVIDYA, N. A. (2015) Twitter Sentiment Analysis Terhadap Brand Reputation: Studi Kasus PT XL AXIATA Tbk. Universitas Indonesia.eputation: Studi Kasus PT XL AXIATA Tbk.," Universitas Indonesia, 2015.
- [4] S. Mujilawati, "Pre-Processing Text Mining Pada Data Twitter," *Semin. Nas. Teknol. Inf. dan Komun.*, vol. 01, pp. 49–56, 2016.
- [5] L. N. Pradany and C. Fatichah, "Analisa Sentimen Kebijakan Pemerintah Pada Konten Twitter Berbahasa Indonesia Menggunakan SVN dan K-Medoid Clustering," *SCAN-Jurnal Teknol. Inf. dan Komun.*, vol. 11, no. 1, pp. 59–66, 2016.
- [6] Informatikalogi, "Text Preprocessing," *https://informatikalogi.com*, 2016. <https://informatikalogi.com/text-preprocessing/> (accessed Apr. 29, 2020).
- [7] B. Herwijayanti, D. E. Ratnawati, and L. Muflikhah, "Klasifikasi Berita Online dengan menggunakan Pembobotan TF-IDF dan Cosine Similarity," *Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 2, no. 1, pp. 306–312, 2018.