

## Implementasi Analisis Sentimen Opini Publik Mengenai Sirkuit Internasional Mandalika Pada Twitter Menggunakan Metode *Multinomial Naïve Bayes Classifier*

Syamsul Mujahidin<sup>1</sup>, Muhamad Nur Hasyim<sup>2</sup>, Bobby Mugi Pratama<sup>3</sup>

Institut Teknologi Kalimantan<sup>1,2,3</sup>

[syamsul@lecturer.itk.ac.id](mailto:syamsul@lecturer.itk.ac.id)<sup>1</sup>, [mnhyim76@gmail.com](mailto:mnhyim76@gmail.com)<sup>2</sup>, [bmpratama@lecturer.itk.ac.id](mailto:bmpratama@lecturer.itk.ac.id)<sup>3</sup>

**Abstrak** - Analisis sentimen sangat berguna untuk mengetahui sentimen opini mengenai suatu topik. Hasil analisis dapat digunakan oleh para pemangku kepentingan dalam melakukan pengambilan keputusan ataupun melihat respon publik terhadap suatu kebijakan. Namun demikian, analisis sentimen yang dilakukan secara manual tentunya memerlukan waktu dan sumber daya yang tidak sedikit. Penelitian ini bertujuan untuk membangun sebuah sistem yang mampu melakukan analisis sentimen opini publik mengenai Sirkuit Internasional Mandalika menggunakan metode *Multinomial Naïve Bayes Classifier* secara otomatis melalui media sosial twitter. Metode ini cocok digunakan pada kasus analisis sentimen yang pada umumnya memegang asumsi independensi pada feature-nya dan cocok digunakan pada sistem *real time* karena waktu prediksi dan *training*-nya yang cepat. Dataset yang digunakan pada penelitian ini berjumlah 6184 data *tweet* mentah yang dibagi menjadi data *training* dan data *testing*. Berdasarkan hasil penelitian, model dengan kinerja terbaik didapatkan pada pembagian dataset 90%:10% dan kelas dataset yang diseimbangkan dengan nilai *accuracy* 78%, *precision* pada kelas positif 84% dan pada kelas negatif 73%, *recall* pada kelas positif 70% sedangkan pada kelas negatif 86%, dan nilai *F1-Score* pada kelas positif 76% sedangkan pada kelas negatif 79%. Adapun hasil analisis sentimen pada data tanggal 18 Juni – 28 Juni 2022 adalah 56% *tweet* memiliki sentimen negatif dan 46% *tweet* memiliki sentimen positif.

Kata Kunci : Analisis Sentimen, Mandalika, *Multinomial Naïve Bayes Classifier*, MotoGP, Twitter

**Abstract** - *Sentiment analysis is very useful to find out the sentiment of opinion about a topic. The results of the analysis can be used by stakeholders in making decisions or seeing the public's response to a policy. However, sentiment analysis that conducted manually can need more time and resources. This study aims to build a system capable of analyzing public opinion sentiment regarding the Mandalika International Circuit using the Multinomial Naïve Bayes Classifier method automatically through social media twitter. This method is suitable for use in the case of sentiment analysis which generally holds the assumption of independence in its features and is suitable for use in real time systems because of its fast prediction and training time. The dataset used in this study amounted to 6184 raw tweet data which was divided into training data and testing data. Based on the results of the study, the model with the best performance was obtained in the distribution of the dataset of 90%:10% and the balanced dataset class with an accuracy value of 78%, precision in the positive class 84% and in the negative class 73%, recall in the positive class 70% while the negative 86%, and the F1-Score value in the positive class is 76% while the negative class is 79%. The results of sentiment analysis on data from June 18 to June 28 2022 are 56% of tweets have negative sentiments and 46% of tweets have positive sentiments.*

**Keywords:** *Sentiment Analysis, Mandalika, Multinomial Naïve Bayes Classifier, MotoGP, Twitter*

### I. PENDAHULUAN

Perkembangan teknologi internet yang semakin cepat memunculkan berbagai cara baru bagi manusia untuk saling berkomunikasi, salah satunya adalah melalui media sosial. Media sosial adalah sebuah media komunikasi yang bersifat terbuka dan tak terbatas serta memungkinkan masyarakat dapat mengemukakan pendapat atau opini mereka secara bebas (Pamungkas & Setiyanto, 2014). Dari berbagai jenis media sosial yang sering digunakan oleh masyarakat Indonesia, Twitter merupakan salah satu media sosial yang cukup banyak diminati dengan persentase pengguna bulanan sebesar 58.3% untuk menyampaikan opini (Data Reportal, 2022).

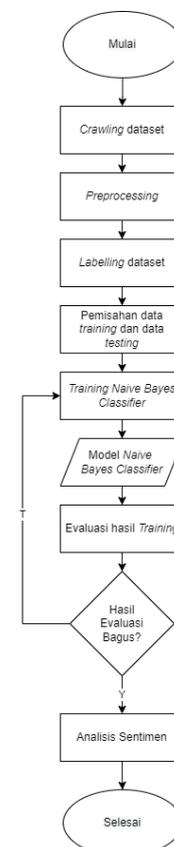
Opini yang disampaikan oleh masyarakat tentang suatu topik melalui media twitter dapat memiliki sentimen yang bersifat negatif atau positif. Analisis sentimen adalah studi secara matematis mengenai pemikiran dan opini seseorang yang dapat bernilai positif ataupun negatif mengenai suatu produk atau peristiwa melalui *Natural Language Processing* (Rasool et al., 2019). Menurut (Ardhiansyah et al., 2019) analisis sentimen sangat berguna untuk menganalisis komentar-komentar yang terdapat pada Twitter untuk diterjemahkan kedalam bentuk yang lebih bermakna. Data yang didapatkan melalui sentimen analisis akan sangat berguna bagi pihak pengambil keputusan dan pihak berwenang apabila digabungkan dengan visualisasi dan metode pemfilteran (Pozzi et al., 2016).

Salah satu algoritma yang dapat digunakan dalam melakukan analisis sentimen adalah *Naïve Bayes Classifier*. *Naïve Bayes Classifier* adalah algoritma probabilitas sederhana yang menghitung satu set probabilitas dengan menghitung frekuensi dan kombinasi nilai pada sekumpulan data (Patil & Sherekar, 2013). Salah satu kelebihan dari *Naïve Bayes Classifier* adalah proses klasifikasi data dapat disesuaikan dengan sifat dan kebutuhan masing-masing (Gunawan et al., 2018). Analisis sentimen pada Twitter menggunakan metode *Naïve Bayes Classifier* sebelumnya sudah pernah dilakukan oleh (Pintoko & L., 2018) dengan hasil akurasi sebesar 86,80%. *Naïve Bayes Classifier* merupakan salah satu metode analisis sentimen yang cukup akurat, hal ini dapat dilihat pada penelitian yang telah dilakukan oleh (Wibawa, 2018) menunjukkan hasil bahwa metode *Naïve Bayes Classifier* lebih unggul daripada metode *K-Nearest Neighbor* dalam melakukan klasifikasi artikel jurnal berbahasa Indonesia. Dari 40 artikel jurnal berbahasa Indonesia metode *Naïve Bayes Classifier* berhasil mengklasifikasikan sebanyak 28 dokumen, sedangkan *K-Nearest Neighbor* hanya dapat mengklasifikasikan 16 dokumen dengan benar. Akurasi pada metode *Naïve Bayes Classifier* juga dapat ditingkatkan dengan menambahkan ekstraksi fitur *n-gram* seperti pada penelitian yang dilakukan oleh (Nugroho, 2018) penambahan ekstraksi fitur *n-gram* meningkatkan nilai akurasi dari 89,67% menjadi 92,00%. Metode *Lexicon Based* yang digunakan oleh penulis juga digunakan oleh (Salim & Mayary, 2020) yang kemudian digabungkan dengan metode *K-Nearest Neighbor* sehingga menghasilkan model dengan akurasi sebesar 94,05% dan 76,31%. Dipilihnya Sirkuit Internasional Mandalika sebagai tempat ajang pegelaran MotoGP 2022 menimbulkan berbagai opini dari masyarakat. Hal ini mengakibatkan jumlah diskusi terkait dSirkuit Internasional Mandalika pada media sosial Twitter menjadi meningkat. Oleh karena itu penulis melakukan penelitian ini guna mengetahui sentimen opini publik mengenai sirkuit internasional Mandalika pada twitter menggunakan algoritma *Naïve Bayes Classifier*.

## II. METODOLOGI PENELITIAN

Dalam penelitian ini terdapat beberapa tahapan yang akan dilakukan seperti yang ditunjukkan pada Gambar 1. Langkah pertama yakni pengumpulan dataset dengan cara melakukan *crawling* menggunakan *API* resmi Twitter kedalam file berformat *.csv*. Berikutnya melakukan *preprocessing* dengan tujuan mengubah data yang telah didapatkan pada proses *crawling* ke dalam bentuk yang lebih mudah diolah oleh komputer. Adapun tahapan *preprocessing* yang akan dilakukan pada penelitian ini meliputi proses *cleaning tweet*,

*normalization*, penghapusan *stopwords*, *stemming*, *tokenization*, dan penghapusan data kosong dan duplikat. Selanjutnya dilakukan proses *labelling* secara otomatis dengan metode *Lexicon-based* menggunakan dataset kamus *lexicon* positif dan negatif berbahasa Indonesia. Lalu dilakukan pemisahan dataset menjadi data *training* dan data *testing*. Beritkunya dilakukan proses *training* model menggunakan metode *Naïve Bayes Classifier* sehingga menghasilkan sebuah model klasifikasi. Selanjutnya dilakukan evaluasi performa model menggunakan *confusion matrix* guna mengetahui nilai *accuracy*, *precision*, dan *recall* dari model yang telah dibuat. Lalu penulis akan melakukan analisis sentimen opini publik mengenai Sirkuit Internasional Mandalika menggunakan data baru yang belum dikenali oleh model.



Sumber: Hasil Penelitian (2022)

Gambar 1. Diagram Alir Penelitian

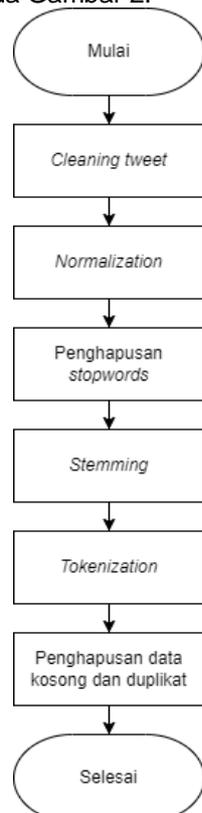
### 1. *Crawling Dataset*

Pada tahap *crawling* dataset penulis menggunakan *API* yang telah disediakan oleh pihak Twitter yang dapat di akses pada laman resmi Twitter. Sebelum mendapatkan akses pada *API* Twitter, penulis harus mendaftar ke laman pengembang Twitter agar mendapatkan akses ke *dashboard* pengembang Twitter. Pada *dashboard* pengembang Twitter, penulis membuat sebuah *project* baru yang berisi satu *app environment* dengan tipe *development* dan menerima *API key* yang terhubung dengan

*environment* tersebut. Pada akun yang digunakan oleh penulis *tweet* yang dapat di-*crawl* dibatasi sebanyak 2 juta *tweet* per-bulan. Adapun data yang didapatkan yaitu *id tweet*, tanggal dibuatnya *tweet* dan isi *tweet* tersebut yang kemudian disimpan ke dalam file dengan format *csv*.

## 2. Preprocessing

Pada tahap ini penulis akan melakukan *preprocessing* terhadap data yang telah didapatkan pada tahap sebelumnya seperti yang ditunjukkan pada Gambar 2.



Sumber: Hasil Penelitian (2022)

Gambar 2. Diagram Alir *Preprocessing*

Penulis menggunakan beberapa metode *preprocessing* antara lain yaitu *cleaning tweet* berfungsi untuk menghapus *mention*, tagar, simbol dan emoji serta melakukan transformasi huruf kapital menjadi huruf kecil pada sebuah *tweet*. *Normalization* berfungsi untuk mengubah kata tidak baku ataupun singkatan pada sebuah *tweet* menjadi ke dalam bentuk bakunya, misalnya kata “mkn” akan diubah menjadi “makan”. Selanjutnya adalah penghapusan *stopwords* yang berfungsi untuk menghapus kata-kata yang tidak penting atau tidak menambah makna pada sebuah kalimat seperti kata “adalah”, “yang”, dan lain-lain. Lalu dilanjutkan dengan tahapan *stemming* yang berfungsi untuk mengubah suatu kata menjadi ke bentuk dasarnya misalnya kata “memakan” akan diubah menjadi “makan”. Selanjutnya adalah tahap *tokenization* yang berfungsi untuk melakukan pemisahan kalimat menjadi bagian-bagian kecil yang disebut token. Dan yang

terakhir dilakukan penghapusan data kosong dan data duplikat, data kosong pada dataset dapat terjadi ketika sebuah *tweet* hanya berisi emoji atau karakter khusus sehingga ketika melalui tahapan *preprocessing* akan menghasilkan *tweet* kosong.

## 3. Labelling Dataset

Pada tahap ini penulis melakukan proses *labelling* sentimen pada dataset yang telah didapatkan sebelumnya. Terdapat dua label sentimen yang digunakan pada penelitian ini yaitu sentimen negatif direpresentasikan sebagai angka 0 dan sentimen positif sebagai angka 1. Penulis melakukan proses *labelling* ini secara otomatis menggunakan metode *Lexicon-based* dengan kamus *lexicon* positif sebanyak 3610 kata dan kamus *lexicon* negatif sebanyak 6610 kata.

## 4. Pemisahan Data

Pada tahap ini penulis melakukan pemisahan dataset menjadi data *training* dan data *testing*. Pemisahan dataset yang akan digunakan oleh penulis menjadi data *training* dan data *testing* akan dilakukan secara acak. Dataset yang telah melalui tahap *preprocessing* memiliki jumlah 5970 *tweet* kemudian akan dibagi menjadi data *training* yang akan digunakan untuk melakukan pelatihan model dan data *testing* yang akan digunakan untuk melakukan pengujian performa model.

## 5. Training Naïve Bayes Classifier

Langkah pertama pada proses *training* adalah melakukan input data *training* yang telah melalui tahapan *preprocessing*. Selanjutnya adalah melakukan pembangunan kamus frekuensi kata pada data *training*, pada tahapan ini penulis menggunakan pendekatan model *Bag-of-words* yang menghitung tiap kemunculan kata pada data *training* serta melakukan proses *Laplacian Smoothing* guna menghindari kondisi dimana suatu kata hanya muncul pada salah satu kelas dan tidak pada kelas lainnya. Selanjutnya hitung *prior probability* pada tiap kelas menggunakan Persamaan (1) berikut.

$$\hat{P}(A) = \frac{N_A}{N_{Doc}} \dots\dots\dots (1)$$

Keterangan:

- $\hat{P}(A)$  = *Prior probability* kelas A
- $N_A$  = Jumlah dokumen pada data latih kelas A
- $N_{Doc}$  = Jumlah dokumen secara keseluruhan

Dimana  $\hat{P}(A)$  adalah *prior probability* kelas A,  $N_A$  adalah jumlah dokumen pada data *training* yang masuk ke dalam kelas A, dan  $N_{Doc}$  adalah jumlah dokumen secara keseluruhan. Setelah nilai *prior probability* telah didapatkan maka langkah selanjutnya adalah melakukan perhitungan *likelihood* pada tiap kata pada dataset menggunakan Persamaan (2) berikut.

$$P(w_i|c) = \frac{\text{count}(w_i, c) + 1}{(\sum_{w \in V} \text{count}(w, c)) + |V|} \dots\dots\dots (2)$$

Keterangan:

- $P(w_i|c)$  = Likelihood kata  $w_i$  pada kelas  $c$
- $\text{count}(w_i, c)$  = Frekuensi kata  $w_i$  pada kelas  $c$
- $V$  = Jumlah semua kata pada seluruh kelas

Dimana  $P(w_i|c)$  adalah *likelihood* kata  $w_i$  pada kelas  $c$ ,  $\text{count}(w_i, c)$  adalah frekuensi kata  $w_i$  pada kelas  $c$ , dan  $V$  jumlah semua kata pada seluruh kelas.

**6. Evaluasi Hasil Training**

Pada tahap evaluasi penulis menggunakan *confusion matrix* guna mengukur tingkat *accuracy*, *precision*, dan *recall* dari model yang telah dilatih pada tahap sebelumnya. Dikarenakan label yang digunakan pada penelitian ini hanya berjumlah dua label (positif dan negatif) maka *confusion matrix* yang digunakan pada penelitian ini berbentuk matriks 2 x 2. Adapun Persamaan (3), (4), dan (5) merupakan persamaan yang digunakan untuk melakukan perhitungan *accuracy*, *precision*, dan *recall*.

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + TN + FN} \dots\dots\dots (3)$$

$$\text{Precision} = \frac{TP}{TP + FP} \dots\dots\dots (4)$$

$$\text{Recall} = \frac{TP}{TP + FN} \dots\dots\dots (5)$$

Keterangan:

- $TP$  = True Positive
- $TN$  = True Negative
- $FP$  = False Positive
- $FN$  = False Negative

Dimana  $TP$  adalah *True Positive* yaitu item yang bernilai positif berhasil dan hasil prediksinya juga positif,  $TN$  adalah *True Negative* yaitu item bernilai negatif dan hasil prediksinya juga negatif,  $FP$  adalah *False Positive* yaitu item yang bernilai negatif tetapi hasil prediksinya merupakan positif, dan  $FN$  adalah *False Negative* yaitu item yang bernilai positif tetapi hasil prediksinya merupakan negatif.

**7. Analisis Sentimen**

Setelah model *Naïve Bayes Classifier* berhasil dibangun, maka didapatkanlah nilai *prior probability* tiap kelas dan nilai *likelihood* tiap kata. Model yang telah dibangun dapat digunakan untuk melakukan analisis sentimen terhadap data baru yang belum dikenali. Adapun Persamaan (6) berikut merupakan persamaan yang digunakan dalam melakukan analisis sentimen suatu tweet

$$\hat{c} = \underset{a \in A}{\text{argmax}} \log P(c) + \sum_{i \in \text{positions}} \log p(w_i|c) \dots (1)$$

Keterangan:

- $\log P(c)$  = Nilai logaritma natural dari *prior probability*
- $\log p(w_i|c)$  = Nilai logaritma natural dari *likelihood* suatu kata

Dimana  $\log P(c)$  adalah nilai logaritma natural dari *prior probability* sedangkan  $\log p(w_i|c)$  adalah nilai logaritma natural dari *likelihood* suatu kata.

**III. HASIL DAN PEMBAHASAN**

**1. Crawling Dataset**

Proses *crawling dataset* pada Twitter dilakukan menggunakan *API* resmi dengan *query* “mandalika” dan tidak mengikutsertakan *retweet*. Proses ini menghasilkan data berupa *tweet* mentah sebanyak 6183 mulai dari tanggal 12 Februari 2022 hingga 20 Februari 2022. Adapun Tabel 1 berikut merupakan contoh hasil *crawling dataset* yang dilakukan penulis.

Tabel 1. Contoh Hasil *Crawling Dataset*

ID	Date	Tweet
		@LahrianSyahilla Salut sama pertamina dalam sukseskan Event MotoGP
149516558 523971584 0	19-Feb- 2022 (22:37:09)	Mandalika, Pertamina Jamin Ketersediaan Energi di NTB @abu_waras Dari awal sampe skrg masalah ada aja di mandalika ini, dari unboxing motor, banjir, ujan kagak berenti2, ampe aspalnya kyk
149522084 701104947 2	20-Feb- 2022 (02:16:44)	bangunan kurang smen, dan ternyata warga yang tanahnya tergusurpun belum mendapatkan ganti rugi ini salah satu do'a yang teraniaya

Sumber: Hasil Penelitian (2022)

*Tweet* yang didapatkan pada tahap *crawling* akan disimpan ke dalam file *csv* dengan tiga kolom yaitu *id*, *date*, dan *tweet*.

**2. Preprocessing**

Pada penelitian ini penulis melakukan beberapa tahapan *preprocessing* terhadap dataset yang akan digunakan, adapun tahapan-tahapan *preprocessing* tersebut antara lain yaitu *cleaning tweet*, penghapusan

data kosong dan duplikat, *normalization*, penghapusan *stopwords*, *stemming*, dan *tokenization*. Tahap *preprocessing* harus dilakukan sesuai urutan agar tiap-tiap tweet yang melalui tahap *preprocessing* dapat diubah ke bentuk yang lebih mudah diolah oleh komputer.

### 3. Labelling Dataset

*Labelling* data dilakukan secara otomatis menggunakan metode *Lexicon-based*. Metode *Lexicon-based* akan melakukan perhitungan sentimen *tweet* dengan cara menambahkan nilai sentimen tiap kata. Jika total nilai sentimen tiap kata lebih dari 0 maka kalimat tersebut dianggap memiliki sentimen positif lalu sebaliknya jika total nilai sentimen tiap kata kurang dari 0 maka kalimat tersebut dianggap memiliki sentimen negatif. Adapun Tabel 2 berikut merupakan contoh hasil *labelling* pada dataset yang digunakan.

Tabel 2. Contoh Hasil *Labelling Dataset*

No	Tweet	Sentimen
1	@son_of_adam Wow mantap nih, sukseskan event MotoGP Mandalika @CNNIndonesia Bikin malu2 bangsa sendiri, kami sudah banga2kan ke	Positif
2	negara lain kalau aspal mandalika adalah aspal terbaik d dunia eee belum d pake secara resmi mala d aspal ulang,	Negatif

Sumber: Hasil Penelitian (2022)

Hasil dari tahap *labelling* dataset menggunakan metode *Lexicon-based* yang dilakukan terhadap 5970 data yang telah melalui tahap *preprocessing* oleh penulis menunjukkan bahwa 3100 data memiliki label negatif dan 2870 memiliki label positif. Pada penelitian ini penulis menggunakan 4 variasi dataset yang dapat dilihat pada Tabel 3 berikut ini.

Tabel 3. Variasi Dataset Penelitian

No	Tweet
1	Dataset normal
2	Jumlah data diseimbangkan
3	Perbaikan hasil labelling
4	Perbaikan hasil labelling dan Jumlah data diseimbangkan

Sumber: Hasil Penelitian (2022)

Variasi dataset 1 merupakan dataset normal yang tidak dilakukan manipulasi apapun. Variasi dataset 2 merupakan dataset yang jumlah data pada tiap kelasnya disamakan dengan cara melakukan penghapusan data pada kelas yang berlebih secara acak. Variasi dataset 3 merupakan dataset yang telah dilakukan perbaikan pada hasil *labelling*, pada kasus ini penulis melakukan perbaikan label terhadap 77 baris data. Variasi dataset 4 merupakan dataset yang telah dilakukan

perbaikan pada hasil *labelling* lalu dilakukan penyetaraan jumlah data positif dan negatif.

### 4. Pemisahan Dataset

Pemisahan dataset bertujuan untuk menentukan data *training* dan data *testing*. Data *training* akan digunakan untuk melatih model klasifikasi *Naïve Bayes Classifier* sedangkan data *testing* akan digunakan untuk melakukan pengujian performa model. Adapun Tabel 4 berikut ini menunjukkan pembagian dataset yang akan dilakukan oleh penulis pada penelitian ini.

Tabel 4. Pembagian Dataset Penelitian

No	Data Training	Data Testing
1	90%	10%
2	80%	20%
3	70%	30%

Sumber: Hasil Penelitian (2022)

### 5. Training Naïve Bayes Classifier

Pada tahap *training* penulis akan melakukan *training* terhadap menggunakan 4 variasi dataset seperti pada Tabel 3. Penulis akan membangun 4 model dengan 3 variasi pembagian data training dan data testing seperti yang dapat dilihat pada Tabel 4. Langkah pertama dalam tahap *training* model *Naïve Bayes Classifier* adalah melakukan ekstraksi fitur dari dataset. Penulis menggunakan metode ekstraksi fitur *Bag-of-Words* yang akan menghitung frekuensi kemunculan tiap kata pada tiap kelas lalu menyimpannya ke sebuah dictionary dalam bentuk {(kata, frekuensi), kelas}. Adapun hasil pembentukan *Bag-of-Words* yang dilakukan penulis dapat dilihat pada Gambar 3 berikut.

```
{('bayang', 0): 11, ('balap', 0): 581, ('lap', 0): 27,
('quartararo', 0): 11, ('aprilia', 0): 4, ('aleix', 0): 18,
('espargaro', 0): 25, ('trek', 0): 46, ('sirkuit', 0): 1087,
('mandalika', 0): 2607, ('lintas', 0): 78, ('motocross', 0): 1,
('awas', 0): 9, ('nyasar', 0): 3, ('ngebut', 0): 6, ('an', 0): 34,
('benar', 0): 26, ('beli', 0): 54, ('tiket', 0): 88, ('tonton',
0): 195, ('bang', 0): 30, ('yuk', 1): 30, ('mandalika', 1): 2367,
('evaluasi', 1): 15, ('testimoni', 1): 2, ('rider', 1): 60,
('dibenerin', 1): 1, ('aman', 1): 40, ('bulan', 1): 4, ('hops',
0): 1, ('framing', 0): 14, ('jelek', 0): 112, ('fe', 0): 9,
('malu', 0): 68, ('ribut', 0): 25, ('maju', 0): 18, ('indonesia',
0): 216, ('respond', 0): 1, ('masyarakat', 0): 16, ('pro', 0): 13,
('kontra', 0): 8, ('wajar', 0): 63, ('dapat', 0): 9, ('ayo', 0):
13, ('lurus', 0): 5, ('positive', 0): 2, ('vibanya', 0): 1,
('akhir', 0): 3, ('komentar', 0): 37, ('masuk', 0): 87, ('iya',
1): 26, ('dongs', 1): 1, ('negara', 1): 31, ('nobat', 1): 3,
('indah', 1): 75, ('dunia', 1): 127, ('meagalahkan', 1): 1,
('new', 1): 1, ('zealand', 1): 1, ('sirkuit', 1): 840, ('bangga',
1): 139, ('emak', 1): 3, ('ucap', 1): 1, ('terlma', 1): 39,
('kasih', 1): 43, ('ncu', 1): 1, ('presiden', 1): 40, ('serta',
1): 5, ('dukung', 1): 118, ('kerja', 1): 71, ('kah', 1): 9,
('hitung', 1): 5, ('an', 1): 14, ('selenggara', 1): 47, ('raup',
1): 1, ('untung', 1): 19, ('besar', 1): 7, ('om', 1): 18,
('motogp', 1): 581, ('wak', 1): 2, ('haji', 1): 4, ('dunlop', 1):
1, ('test', 1): 52, ('pakai', 1): 87, ('referensi', 1): 1,
('asia', 1): 7, ('talent', 1): 2, ('cup', 1): 2, ('bareng', 1):
11, ('msbk', 1): 30, ('kamarin', 1): 45, ('ho', 0): 24, ('wis',
0): 2, ('moleh', 0): 1, ('sesuk', 0): 1, ('mrene', 0): 1, ('teh',
0): 5, ('montor', 0): 1, ('nang', 0): 10, ('bilang', 0): 105,
('kadrun', 0): 199, ('motogp', 0): 551, ('jalan', 0): 96, ('tol',
0): 21, ('bangun', 0): 133, ('bidang', 0): 2, ('parimisata', 0):
15, ('basis', 0): 1, ('jabar', 0): 3, ('sumbar', 0): 1, ('porsi',
```

Sumber : Hasil Penelitian (2022)

Gambar 3. Hasil Pembentukan *Bag-of-Words*

Setelah dictionary *Bag-of-Words* berhasil dibuat maka langkah selanjutnya adalah menghitung *prior probability*. Perhitungan *prior probability* dapat dilakukan dengan menggunakan Persamaan (1). Lalu langkah selanjutnya adalah melakukan perhitungan *likelihood* tiap kata pada data *training* menggunakan Persamaan (2). Output dari hasil *training* pada model *Naïve Bayes Classifier* adalah nilai *prior probability* dan *likelihood* seluruh kata pada training set.

### 6. Evaluasi Hasil Training

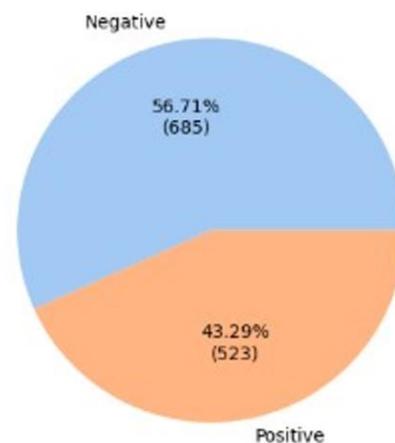
Setelah melakukan tahap training *model Naïve Bayes Classifier* maka selanjutnya penulis akan melakukan evaluasi hasil *training*. Evaluasi hasil *training* dilakukan dengan menggunakan *confusion matrix*. Adapun metrik yang akan diukur pada tahap evaluasi adalah *accuracy*, *precision*, *recall*, dan *f1-score*. Hasil evaluasi model *Naïve Bayes Classifier* yang telah dibangun dalam 4 case dataset yang berbeda dapat dilihat pada Tabel 5.

Tabel 5 menunjukkan hasil evaluasi terhadap model yang dilatih pada tahap sebelumnya, kolom "Variasi dataset" berisi variasi dataset yang digunakan oleh model terkait sesuai dengan Tabel 3, adapun kolom "Pembagian dataset" berisi pembagian dataset yang digunakan oleh model sesuai dengan Tabel 4, kolom "Accuracy" berisi nilai *accuracy* dari model terkait pada data kelas positif dan negatif yang dihitung dengan Persamaan (3), kolom "Precision" berisi nilai *precision* dari model terkait pada data kelas positif dan negatif yang dihitung dengan Persamaan (4), kolom "Recall" berisi nilai *recall* dari model terkait pada data kelas positif dan negatif yang dihitung dengan Persamaan (5), kolom "F1-Score" berisi nilai *mean* dari *precision* dan *recall*, dan kolom "Support" berisi jumlah data pada masing-masing kelas sentimen. Penulis melakukan pelatihan model menggunakan 4 variasi dataset yang dapat dilihat pada Tabel 3 dan 3 variasi pembagian data *training* - data *testing* seperti pada Tabel 4 sehingga menghasilkan 12 model klasifikasi. Dari hasil percobaan yang dilakukan oleh penulis pada Tabel 5 dapat dilihat bahwa percobaan yang menggunakan variasi dataset 2 dengan pembagian dataset 90% data *training* dan 10% data *testing* merupakan model dengan hasil evaluasi

terbaik yang memiliki nilai *accuracy* sebesar 78%, *precision* pada kelas positif 84% dan pada kelas negatif 73%, *recall* pada kelas positif 70% sedangkan pada kelas negatif 86%, dan nilai *F1-Score* 76% pada kelas positif sedangkan pada kelas negatif memiliki nilai 79%.

### 7. Analisis Sentimen

Adapun dataset yang akan dianalisis sentimennya adalah dataset dari hasil *crawling* pada tanggal 18 Juni 2022 – 28 Juni 2022. Analisis sentimen *tweet* dilakukan dengan menggunakan Persamaan (6). Setelah penulis melakukan tahap *crawling*, didapatkanlah dataset mentah sebanyak 1287 *tweet*. Dataset yang didapatkan pada tahap *crawling* akan melalui tahap *preprocessing* dan juga *labelling* sehingga menyisakan dataset dengan jumlah 1208. Model yang digunakan untuk mengklasifikasikan sentimen pada dataset yang telah didapatkan adalah model dengan hasil evaluasi terbaik yaitu model yang dibangun menggunakan variasi dataset 2 dengan pembagian dataset 90% data *training* dan 10% data *testing*. Adapun Gambar 4 berikut merupakan *piechart* yang berisi hasil analisis sentimen opini publik terhadap topik Sirkuit Internasional Mandalika menggunakan model yang telah dibangun.



Sumber: Hasil Penelitian (2022)

Gambar 4. Hasil Analisis Sentimen  
 Gambar 4 merupakan *piechart* yang menunjukkan hasil analisis sentimen yang dilakukan penulis terhadap dataset hasil *crawling* dengan tanggal 18 Juni 2022 – 28 Juni 2022. Dapat dilihat dari Gambar 4 bahwa sentimen opini publik mengenai Sirkuit Internasional Mandalika pada tanggal 18 Juni 2022 – 28 Juni 2022 lebih dominan negatif dengan nilai 56.71%.

Tabel 5. Hasil Evaluasi Model

No	Pembagian Dataset	Accuracy	Precision		Recall		F1-Score		Support	
			+	-	+	-	+	-	+	-
1	90% : 10%	0.75	0.78	0.74	0.63	0.85	0.70	0.79	269	328
	80% : 20%	0.78	0.81	0.76	0.69	0.86	0.74	0.81	551	643
	70% : 30%	0.78	0.80	0.77	0.69	0.86	0.74	0.81	825	966
2	90% : 10%	0.78	0.84	0.73	0.70	0.86	0.76	0.79	297	277
	80% : 20%	0.76	0.81	0.72	0.66	0.85	0.73	0.78	586	562
	70% : 30%	0.76	0.81	0.72	0.69	0.84	0.74	0.78	870	852
3	90% : 10%	0.75	0.78	0.73	0.64	0.84	0.70	0.78	276	321
	80% : 20%	0.78	0.81	0.75	0.69	0.85	0.75	0.80	566	628
	70% : 30%	0.77	0.80	0.76	0.70	0.84	0.74	0.80	847	944
4	90% : 10%	0.77	0.78	0.76	0.74	0.80	0.76	0.78	291	298
	80% : 20%	0.74	0.77	0.72	0.69	0.80	0.73	0.76	593	586
	70% : 30%	0.76	0.78	0.74	0.71	0.81	0.74	0.77	864	904

Sumber: Hasil Penelitian (2022)

#### IV. KESIMPULAN

Analisis sentimen dilakukan oleh penulis guna mengetahui sentimen opini publik terhadap Sirkuit Internasional Mandalika serta bagaimana performa model *Multinomial Naive Bayes Classifier* yang dilatih menggunakan dataset hasil crawling pada Twitter dengan kata kunci "Mandalika". Setelah penelitian selesai dilakukan didapatkanlah model terbaik dari yang dibangun dengan menggunakan dataset yang kelas positif dan negatifnya diseimbangkan sehingga total dataset menjadi 5740 *tweet*, serta dilakukan pembagian dataset menjadi 90% data *training* dan 10% data *testing*. Adapun hasil evaluasi model tersebut menunjukkan nilai *accuracy* sebesar 78%, *precision* pada kelas positif 84% dan pada kelas negatif 73%, *recall* pada kelas positif 70% dan pada kelas negatif 86%, dan nilai F1-Score 76% pada kelas positif sedangkan pada kelas negatif memiliki nilai 79%. Kemudian ketika model tersebut dipakai untuk menganalisis sentimen opini publik mengenai topik Sirkuit Internasional Mandalika pada tanggal 18 Juni 2022 – 28 Juni 2022 dengan menggunakan data baru yang belum dikenali sebanyak 1210 *tweet* diperoleh hasil yaitu 56.71% *tweet* memiliki sentimen negatif dan 43.29% *tweet* memiliki sentimen positif sehingga dapat disimpulkan bahwa sentimen opini publik lebih dominan negatif.

#### V. REFERENSI

- Ardhiansyah, M. N., Umar, R., & Sunardi. (2019). Analisis Sentimen pada Twitter Menggunakan Metode Support Vector Machine. Seminar Nasional Teknologi Fakultas Teknik Universitas Krisnadwipayana, 1(1), 739–742.
- <https://jurnal.teknikunkris.ac.id/index.php/se-mnastek2019/article/view/343/342>
- Data Reportal. (2022). Digital 2022: Indonesia — DataReportal – Global Digital Insights. <https://datareportal.com/reports/digital-2022-indonesia>
- Gunawan, B., Pratiwi, H. S., & Pratama, E. E. (2018). Sistem Analisis Sentimen pada Ulasan Produk Menggunakan Metode Naive Bayes. Jurnal Edukasi Dan Penelitian Informatika (JEPIN), 4(2), 113. <https://doi.org/10.26418/jp.v4i2.27526>
- Liu, B. (2018). Sentiment Analysis and Opinion Mining. In <http://dx.doi.org/10.2200/S00416ED1V01Y201204HLT016> (Vol. 5, Issue 1). Morgan & Claypool Publishers. <https://doi.org/10.2200/S00416ED1V01Y201204HLT016>
- MGPA. (2022). Mandalika. <https://themandalikagp.com/about>
- Nugroho, A. (2018). Analisis Sentimen Pada Media Sosial Twitter Menggunakan Naive Bayes Classifier Dengan Ekstraksi Fitur N-Gram. J-SAKTI (Jurnal Sains Komputer Dan Informatika), 2(2), 200. <https://doi.org/10.30645/j-sakti.v2i2.83>
- Pamungkas, D. S., & Setiyanto, N. A. (2017). Analisis Sentiment Pada Sosial Media Twitter Menggunakan Naive Bayes Classifier Terhadap Kata Kunci "Kurikulum 2013." Techno.COM.
- Patil, T. R., & Sherekar, M. S. S. (2018). Performance Analysis of Naive Bayes and J48 Classification Algorithm for Data Classification. International Journal Of Computer Science And Applications, 6(2). <http://www.cs.bme.hu/~kiskat/adatb/bank-data->

- Pintoko, B. M., & L., K. M. (2018). Analisis Sentimen Jasa Transportasi Online pada Twitter Menggunakan Metode Naive Bayes Classifier. *E-Proceeding of Engineering*, 5(3), 8121–8130.
- Pozzi, F. A., Fersini, E., Messina, E., & Liu, B. (2017). Sentiment Analysis in Social Networks. In *Sentiment Analysis in Social Networks*.
- Rasool, A., Tao, R., Marjan, K., & Naveed, T. (2019). Twitter Sentiment Analysis: A Case Study for Apparel Brands. 22015. <https://doi.org/10.1088/1742-6596/1176/2/022015>
- Salim, S. S., & Mayary, J. (2020). Analisis Sentimen Pengguna Twitter Terhadap Dompot Elektronik Dengan Metode Lexicon Based Dan K – Nearest Neighbor. *Jurnal Ilmiah Informatika Komputer*, 25(1), 1–17. <https://doi.org/10.35760/ik.2020.v25i1.2411>
- Statista. (2022). • APAC: active social media users by country 2022. <https://www.statista.com/statistics/295606/social-media-mau-asia-pacific-countries/>
- Wibawa, A. P. (2018). Perbandingan Kinerja Metode Naive Bayes dan K-Nearest Neighbor untuk Klasifikasi Artikel Berbahasa Indonesia. <https://doi.org/10.25126/jtiik.201854773>