

## Analisis Opini Pengguna Bank BCA di Twitter Dengan Menggunakan Metode Random Forest dan Boosting

Nur Latifah Kurnianti<sup>1</sup>, Yuliant Sibaroni<sup>2</sup>

<sup>1,2</sup>Fakultas Informatika, Universitas Telkom, Bandung

<sup>1</sup>nurlatifahk@students.telkomuniversity.ac.id, <sup>2</sup>yuliant@telkomuniversity.ac.id

---

### Abstrak

Twitter merupakan salah satu platform media sosial yang memberikan kebebasan pada user untuk membagikan opininya. Tidak sedikit nasabah bank BCA memberikan pengalamannya di twitter, pengalaman yang dituliskan memiliki nilai sentimen yang berupa sentimen negatif, positif, atau netral. Pelayanan bank sangat mempengaruhi reputasi perusahaan, dimana pelayanan yang baik akan membuat nasabah dengan senang hati menitipkan uang mereka pada perusahaan, begitupun sebaliknya. Dalam tugas akhir ini, penulis akan membangun sistem yang dapat mengklasifikasi nilai sentimen menggunakan metode Random Forest dan dioptimalkan dengan metode Boosting. Metode Random Forest digunakan karena mempunyai atribut yang banyak sehingga menghasilkan pohon keputusan dan metode Boosting untuk memperkuat hasil akurasi dari pemodelan sebelumnya. Pemodelan Boosting yang digunakan untuk penelitian ini adalah Adaptive Boosting. Penelitian ini dilakukan untuk mengetahui opini pelayanan bank BCA pada pengguna Twitter. Tahapan penelitian untuk mengetahui tingkat akurasi ini melalui tahap pengambilan data, pengolahan data, klasifikasi dengan metode yang dipilih, dan Evaluasi. Terdapat 2 pemodelan yang dilakukan sehingga dapat dibandingkan kedua performa antara 2 pemodelan tersebut. Dari hasil evaluasi metode Random Forest memiliki tingkat akurasi sebesar 77% dan metode Boosting memiliki tingkat akurasi sebesar 82%. Diketahui bahwa Boosting memiliki tingkat akurasi lebih tinggi 5% dibandingkan Random Forest. Hal ini terjadi karena Adaptive Boosting dapat menoleransi terjadinya data noise.

**Kata kunci :** Opini, Twitter, Random Forest, Boosting, Klasifikasi

---

### Abstract

Twitter is a social media platform that gives users the freedom to share their opinions. Not a few BCA bank customers share their experiences on Twitter, the experiences that are written have sentiment values in the form of negative, positive, or neutral sentiments. Bank services greatly affect the company's reputation, where good service will make customers happy to leave their money with the company, and vice versa. In this final project, the author will build a system that can classify sentiment values using the Random Forest method and optimized with the Boosting method. The Random Forest method is used because it has many attributes to produce a decision tree and the Boosting method to strengthen the results of the accuracy of the previous modeling. The Boosting model used for this research is Adaptive Boosting. This research was conducted to find out the opinion of BCA bank services on Twitter users. The stages of the research to determine the level of accuracy are through the stages of data collection, data processing, classification with the chosen method, and evaluation. There are 2 models that are carried out so that the performance of the two models can be compared. From the results of the evaluation the Random Forest method has an accuracy rate of 77% and the Boosting method has an accuracy rate of 82%. It is known that Boosting has a 5% higher accuracy rate than Random Forest. This happens because Adaptive Boosting can tolerate data noise.

**Keywords:** Opinion, Twitter, Random Forest, Boosting, Classification

---

### 1. Pendahuluan

#### Latar Belakang

Pada industri pelayanan perbankan sangat mencerminkan sikap dari karyawan yang bertugas dalam melayani konsumen perusahaan. Tidak hanya untuk penilaian pribadi, tetapi pelayanan pada perbankan sangat menentukan sikap konsumen dalam penilaian perusahaan, karena sering sekali konsumen yang merasa puas pada pelayanan perusahaan akan lebih loyal dan setia kepada perusahaan dan begitu juga sebaliknya, jika pelayanan perusahaan buruk maka konsumen memiliki kemungkinan untuk berpaling dengan cepat menggunakan jasa perusahaan tersebut. Setiap perusahaan bank mempunyai tujuan untuk memaksimalkan keuntungannya, perusahaan dapat melakukan penawaran produk dan menginginkan kepuasan dari konsumen[1]. Keberadaan Bank BCA yang sudah hadir cukup lama, maka timbulah rasa percaya masyarakat kepada perusahaan dan mulai

menginvestasikan uangnya kepada perusahaan. Dengan demikian bank BCA sudah memiliki cukup banyak nasabah di Indonesia.

Twitter merupakan aplikasi *social media* yang memberikan kebebasan kepada penggunanya untuk mengunggah apapun itu baik teks, foto, maupun video kedalam aplikasinya dengan pandangan dan pemikiran tentang topik tertentu[2]. Tidak sedikit pengguna Bank BCA yang menceritakan pelayanan petugasnya di tuangkan melalui cuitan di Twitter. Terdapat pengguna yang menceritakan dengan kalimat negative karena kekecewaan pada pelayanannya dan ada banyak juga yang menceritakan dengan positive karena merasa puas dengan pelayanan petugas tersebut.

Penelitian sebelumnya yang dilakukan oleh Indriya Dewi[3] tahun 2019 membahas ulasan pada aplikasi Bank BCA dengan metode Analisis Sentimen menggunakan BM25 dan dioptimalkan oleh K-NN. Pada metode BM25 memulai dengan proses pembobotan data terlebih dahulu kemudian dilanjutkan dengan metode K-NN. Penelitian lainnya mengenai Analisis Sentimen yang dilakukan telah oleh Wahyuningtias dan temannya[4] pada tahun 2022 membahas perbandingan Random Forest dengan SVM (Super Vector Machine), algoritma Random Forest mendapatkan nilai akurasi sebesar 94% sedangkan mendapatkan nilai akurasi SVM 93%. Keduanya memiliki hasil yang baik tetapi algoritma Random Forest lebih baik dibandingkan SVM.

Berdasarkan latar belakang yang telah dipaparkan sebelumnya, maka penulis ingin meneliti terkait opini masyarakat di twitter mengenai pelayanan Bank BCA dengan menggunakan metode Random Forest dan Boosting. Hal ini bertujuan untuk memberikan kesimpulan apakah pengguna twitter menyukai atau tidak terhadap pelayanan di Bank BCA.

Penulis menggunakan metode Random Forest agar dapat menganalisa dan mengklasifikasi opini pengguna twitter kepada Bank BCA. Selain itu, metode Random Forest sangatlah cocok untuk pengklasifikasi data sampel yang banyak. Serta keuntungan lainnya adalah dapat mengklasifikasi data yang atributnya tidak lengkap. Kemudian metode Boosting dipilih karena dapat mengurangi kesalahan dan dapat meningkatkan performansi pada metode klasifikasi sebelumnya.

### **Topik dan Batasannya**

Penelitian kali ini akan membangun sistem analisis sentiment pada opini di media sosial Twitter menggunakan metode Random Forest dan Boosting. Pada sistem yang dibangun menggunakan google colab sehingga di rekomendasikan untuk pengguna PC atau laptop. Dataset yang digunakan pada penelitian memiliki batasan yaitu memiliki rentang waktu dan hanya text yang berbahasa Indonesia.

### **Tujuan**

Tujuan dari penelitian ini adalah untuk mengetahui tingkat akurasi nilai sentiment pada pemodelan klasifikasi Random Forest dan Boosting dalam kasus opini pelayanan bank BCA di media sosial Twitter. Pemodelan klasifikasi menggunakan metode Random Forest dan Boosting untuk memprediksi sentiment dari teks opini yang beredar di Twitter terkait dengan layanan bank BCA. Analisis sentiment dari opini pelayanan bank BCA yang terbagi menjadi 3 kategori emosional, yaitu positif, negatif, dan netral. Analisis ini dilakukan untuk memahami bagaimana persepsi dan pandangan pengguna Twitter terhadap pelayanan bank BCA.

### **Organisasi Tulisan**

Rencana perancangan sistem pada penelitian ini adalah:

1. Analisa masalah  
Melakukan pengumpulan referensi data dan mempelajari bahan untuk penelitian yang akan dijadikan bahan acuan pada penelitian.
2. Mengumpulkan data  
Pengumpulan data yang terkait dengan masalah yang telah ditemukan.
3. Analisa data  
Menganalisa data yang telah dikumpulkan sebelumnya dengan menentukan nilai sentiment secara manual dan otomatis dengan menggunakan sistem.
4. Perancangan dan implementasi sistem  
Perancangan sistem dan implementasi sistem untuk menyelesaikan masalah dengan metode Random Forest dan Boosting. Pada tahapan ini juga akan dilakukan *preprocessing* data yaitu dengan *cleaning data*, *stopword removal*, *stemming*, *tokenization*.
5. Pengujian sistem

Pada tahap ini dilakukan pengujian sistem dengan data yang telah disiapkan menggunakan metode Random Forest dan Boosting.

6. Evaluasi

Evaluasi atau kesimpulan untuk mengetahui tingkat kesulitan yang di alami dalam pembuatan sistem untuk memperbaiki kekurangan pada penelitian ini.

## 2. Studi Terkait

Sosial media merupakan platform digital yang menyediakan fasilitas kebebasan untuk penggunanya dalam mengunggah apapun maupun berinteraksi melalui dunia maya. Sosial media merupakan bagian dari pengembangan internet. Hal ini yang membuat semua penggunanya tersambung dengan internet dan kemudian dapat melakukan penyebaran informasi. Sosial media memberikan kemudahan penggunanya dalam berkomunikasi dan memiliki kemampuan untuk menyajikan komunikasi dua arah[5]. Hal ini menjadikan social media bukan hanya sarana berkomunikasi tetapi dapat menjadi sarana pemasaran produk, sehingga dapat menjaga hubungan baik antar perusahaan dengan konsumennya. Twitter dibentuk oleh Jack Dorsey pada tahun 2006. Pengguna aplikasi Twitter sendiri mencatat sebanyak 217 pengguna aktif di Dunia, bahkan di Indonesia berada di peringkat ke-5 dengan jumlahh pengguna sebanyak 18,45 juta[6] . Hal ini berpengaruh pada jumlah tweet yang banyak pada setiap harinya. Aplikasi Twitter hingga sekarang masih digemari penggunanya, bukan hanya aplikasinya yang sederhana, tetapi di Twiiter pengguna dapat memberikan opini, kritik, dan saran pada suatu hal. Tidak jarang untuk menjumpai Thread. Thread adalah istilah pada twitter untuk cuitan berantai.

Penelitian lainnya yang ditulis oleh Ikhlasul Amalia[8] yang menggunakan Adaptive Boosting dan Random Forest, Teknik ensemble mempunyai kemampuan yang baik dalam prediksi peserta dengan tingkat akurasi yang melebihi 80% pada kedua model klasifikasi. Model Random Forest memiliki hasil yang lebih baik pada F1 Score dan AUC dibandingkan model AdaBoost. Hal ini dikarenakan model Random Forest membangun setiap pohon keputusan secara independen dengan data sampel secara acak, hal ini yang membuat model menjadi lebih tahan pada variabilitas.

Pada tahun 2017, Renda Dwi[9] telah melakukan penelitian tentang informasi gempa menggunakan metode Random Forest dan beberapa metode lainnya. Penelitian tersebut menunjukkan bahwa dalam analisis tweet yang berisi informasi tentang gempa, penggunaan metode Random Forest menunjukkan tingkat Recall sebesar 96,7% hal ini mengungguli kinerja metode Decision Tree dan SVM. Pada metode SVM menghasilkan tingkat Recall hanya 63,3% dan metode Decision Tree 40%. Dalam studi tersebut, para peneliti memanfaatkan 2278 kiriman di platform media sosial yang mengandung kata 'gempa'. Data tersebut diambil dari rentang waktu mulai 20 September 2014 hingga 25 September 2014, kemudian dari 20 Desember 2014 hingga 30 Desember 2014, serta periode 1 hingga 15 Januari 2015.

Pada tahun 2021, Muhammad Asjad[10] telah melakukan analisis sentimen pada ulasan film menggunakan metode Random Forest yang di optimasi kembali dengan metode Boosting. Pada penelitian tersebut, peneliti menggunakan 12.000 data kemudian pengujian dengan beberapa skenario. Pada nilai akurasi skenario 1 Boosting Method memiliki nilai paling tinggi yaitu sebesar 75.44%. Kemudian pada skenario kedua, nilai akurasi tertinggi sebesar 75,76% dari dataset yang menggunakan proses stemming dan skip-gram 300 dimensi. Nilai ini mencerminkan ketepatan program dalam menentukan sentimen dari dataset yang terdiri dari hasil review film di situs IMDB.

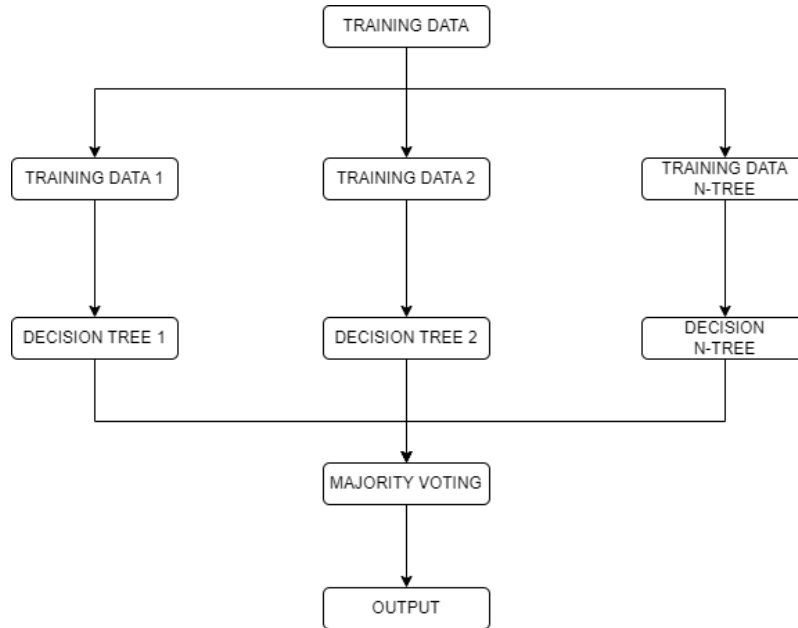
### 2.1 Random Forest

Random Forest merupakan metode pengembangan dari metode Classification and Regression Tree (CART). Random Forest adalah metode klasifikasi yang terdiri dari kumpulan pohon keputusan seperti hutan dan akan melakukan proses seleksi dimana pohon decision tree akan dibagi berdasarkan kelasnya untuk mendapatkan yang terbaik. Random Forest merupakan tipe klasifikasi yang tidak rentan terhadap noise serta outlier karena sifat random yang dimilikinya[10].

Pada metode random forest terdapat 3 aspek didalamnya, yang pertama melakukan bootstrapping sampling terdahulu untuk membangun pohon keputusan. Kemudian masing masing dari pohon

keputusan akan memprediksi dengan prediktor secara acak, dan yang terakhir random forest akan melakukan prediksi dengan mengkombinasikan hasil pada setiap pohon dengan majority vote untuk meng-klasifikasi regresi[14]. Dalam metode Random Forest terdiri dari root node yang merupakan simpul paling atas atau dengan kata lain sebagai akar pohon keputusan, internal node yang berarti simpul percabangan simpul percabangan yang dimana node ini hanya memiliki satu input dan hanya memiliki output minimal dua, dan leafnode atau disebut dengan terminal node yang merupakan simpul terakhir yang tidak memiliki output dan hanya memiliki satu input[15].

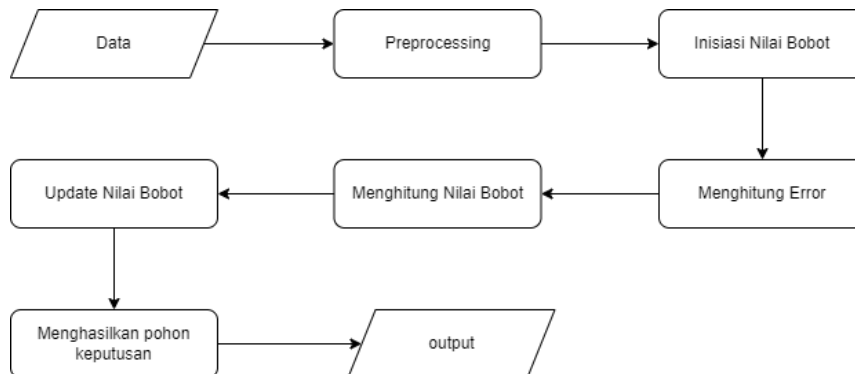
Cara kerja algoritma Random Forest dapat dilihat pada gambar[16]



**Gambar 1 Cara Kerja Random Forest**

## 2.2 Boosting

Adaptive Boosting (AdaBoost) merupakan suatu metode untuk meningkatkan akurasi dari suatu metode klasifikasi. Algoritma AdaBoost dapat mengubah model yang lemah menjadi suatu model yang kuat, hal ini disebabkan algoritma AdaBoost yang berfokus pada pembuatan deret pohon klasifikasi dengan suatu base learner[18]. Cara kerja AdaBoost ialah dimulai dengan memberikan bobot yang sama pada sample data, kemudian menentukan base learner yang merupakan suatu fungsi klasifikasi data sample yang telah diboboti[19]. Cara kerja algoritma Adaptive Boosting dapat dilihat pada gambar 2 [20].



**Gambar 2 Cara Kerja Adaptive Boosting**


Pada gambar 2 merupakan cara kerja pemodelan Adaptive Boosting. Model ini mengulangi proses pemodelan sebelumnya dengan menambahkan model yang lemah berikutnya hingga mencapai tingkat

akurat yang sesuai. Tahapan pada proses model ini adalah setelah dilakukan preprocessing akan dilakukannya inisiasi nilai bobot yaitu setiap contoh dalam data train akan diberikan bobot yang sama pada awalnya, model lemah pertama kali akan dilatih kembali dan akan menghitung prediksi model dengan dibandingkan pada label sebenarnya. Pada perhitungan eror akan menghitung kesalahan pada setiap prediksi dengan perhitungan berdasarkan bobot contoh. Kesalahan tersebut akan menentukan seberapa buruk model lemah dalam melakukan prediksi. Selanjutnya menghitung nilai bobot berdasarkan kesalahan yang dihasilkan sebelumnya, pada contoh yang diprediksi dengan benar akan diberi bobot lebih rendah sementara contoh yang dipredoksi dengan salah akan diberi bobot lebih tinggi. Kemudian model akan memperbarui nilai bobot untuk melatih model lemah berikutnya. Proses ini dilakukan secara berulang hingga model lemah selanjutnya akan lebih fokus pada contoh yang memiliki nilai lebih tinggi.

Adaptive boosting lebih sering menggunakan model yang lemah dan dangkal (*weak learners*) karena cenderung memiliki kinerja yang terbatas jika digunakan sendiri. Pada hasil prediksi data baru, output dari setiap model lemah dijumlahkan secara berbobot. Bobot model lemah ditentukan berdasarkan seberapa akurat model tersebut dalam melakukan prediksinya selama pelatihan. Hasil dari prediksi dijumlahkan kemudian akan menjadi hasil akhir pada pemodelan Adaptive Boosting

### 3. Sistem yang Dibangun

Gambar 1 merupalam perancangan model Random Forest dan Boosting yang akan digunakan pada sistem.



**Gambar 3 Sistem yang dibangun**

#### 3.1 Dataset

Dataset yang digunakan pada penelitian ini melalui proses crawling data dengan menggunakan tools otomatis pada website yang dapat mengambil cuitan pada aplikasi Twitter. Data yang digunakan berupa *datetime* sebagai petunjuk waktu cuitan diupload, *username* sebagai akun pemilik cuitan, dan *content* sebagai isi cuitan dari pemilik akun. Pengambilan data menggunakan keyword “bank BCA” dengan rentang waktu 21 Juni 2020 hingga 8 November 2022. Data tweet yang akan digunakan sebanyak 3139 tweet. Tabel 1 merupakan hasil crawling data dan pelabelan data.

### 3.2 Preprocessing

Preprocessing merupakan proses menghilangkan kata kata yang tidak di inginkan dalam mengklasifikasi data. Hal ini dilakukan bertujuan untuk meningkatkan kinerja saat proses klasifikasi berlangsung, jika masih terdapat kata kata yang tidak diinginkan, hal tersebut akan menurunkan kinerja klasifikasi. Pada tahap preprocessing mencakup empat langkah, yaitu *cleaning*, *stopword removal*, *stemming*, dan *tokenization* [21].

- *Cleaning* : Proses pembersihan tweet pada dataset agar memudahkan proses sehingga dapat menghasilkan nilai akurasi yang tinggi. Pembersihan teks dilakukan dengan menghilangkan tanda baca seperti @mention, hastag, hyperlink, RT, angka yang ada pada string, dan spasi berlebih.
- *Stopword Removal* : Menghapus kata yang tidak dianggap tidak mempunyai pengaruh atau kata yang tidak memiliki arti. Kata kata yang termasuk pada *stopword* adalah “dengan”, “ia”, “bahwa”, dan lainnya. Kamus yang digunakan untuk *stopword removal* penelitian ini menggunakan Sastrawi library.
- *Stemming* : Proses untuk mengidentifikasi kata dasar dengan menghapus awalan, akhiran, dan konfiks. Tujuannya adalah untuk mengubah kata menjadi bentuk yang lebih sederhana. Dalam penelitian ini, digunakan kamus dari Sastrawi library untuk melakukan proses *stemming*.
- *Tokenization* : Langkah untuk pemecahan kalimat menjadi beberapa bagian, tujuan *tokenization* untuk membuang beberapa karakter yang dianggap sebagai tanda baca sehingga membuat lebih mudah pada proses klasifikasi.

**Table 1 Preprocessing**

Content	Beda sih ya memang, bank lokal dasa internasional dengan bank yg emang lahir dari manajemen internasional. Utk saat ini Bank lokal yg udh mirip2 dengan DBS baik manajemen maupun handling casenya, cuma BCA.
Cleaning	beda sih ya memang bank lokal dasa internasional dengan bank yg emang lahir dari manajemen internasional utk saat ini bank lokal yg udh dengan dbs baik manajemen maupun handling casenya cuma bca
Stopword Removal	beda sih memang bank lokal dasa internasional bank memang lahir manajemen internasional saat bank lokal sudah dbs baik manajemen maupun handling casenya cuma bca
Stemming	beda sih memang bank lokal dasa internasional bank memang lahir manajemen internasional saat bank lokal sudah dbs baik manajemen maupun handling case cuma bca
Tokenizantion	beda,sih,memang,bank,lokal,dasa,internasional,bank,memang,lahir, manajemen,internasional,saat,bank,lokal,sudah,dbs,baik,manajemen ,maupun,handling,case,cuma,bca

Pada tahap preprocessing terdapat proses pengubahan slang word untuk mengurangi ambiguitas dan menyederhanakan fitur. Pada dataset, banyak user yang menggunakan kata tidak baku sehingga dapat menyebabkan ketidakjelasan pada klasifikasi. Penelitian ini menggunakan daftar slang word dalam bahasa Indonesia dari GitHub, dalam daftar terdapat kata “bca” yang akan diubah menjadi kata “baca”, untuk menghilangkan bagian tersebut agar sesuai dengan penelitian, penulis menambahkan proses pengecualian pengubahan slang word pada kata bca, yaitu:

```
indo_slang_words = indo_slang_words[indo_slang_words['slang'] != 'bca']
```

### 3.3 Split Data

Split data adalah proses pemisahan dataset menjadi dua bagian yaitu data *train* dan data *test*. Tujuan pemisahan dataset karena data train dan data test memiliki fungsi yang berbeda, data train berfungsi sebagai melatih algoritma pada pencarian model program yang akan digunakan. Sedangkan data test akan digunakan untuk menguji performa pada model program. Proses pembagian data train dan data test memiliki perbandingan 90% dan 10%. Dari dataset yang tersedia sebanyak 3139 tweet, data train sendiri memiliki data sebanyak 2825 tweet dan data test memiliki data sebanyak 314 tweet. Tabel 1 menunjukkan perbandingan data test dan data train

**Table 2 Split Data**

	DATA TRAIN	DATA TEST
POSITIVE	1041	109
NEGATIVE	451	49
NEUTRAL	1333	156

### 3.4 Feature Extraction

Fitur ekstraksi merupakan proses yang mempengaruhi hasil akurasi pada tahap klasifikasi. Fitur ekstraksi berperan untuk memberikan nilai bobot pada setiap kata pada dokumen[22]. Pada proses fitur ekstraksi penelitian ini menggunakan model TF-IDF. TF-IDF atau *term frequency-inverse document frequency* merupakan model untuk melakukan perhitungan bobot pada setiap kata dalam seluruh dokumen[23].

*Term Frequency* (TF) merupakan banyaknya  $i$  pada data  $j$ , kemudian hasilnya akan dibagi dengan total term pada data  $j$ . Berikut adalah rumus untuk menghitung nilai TF :

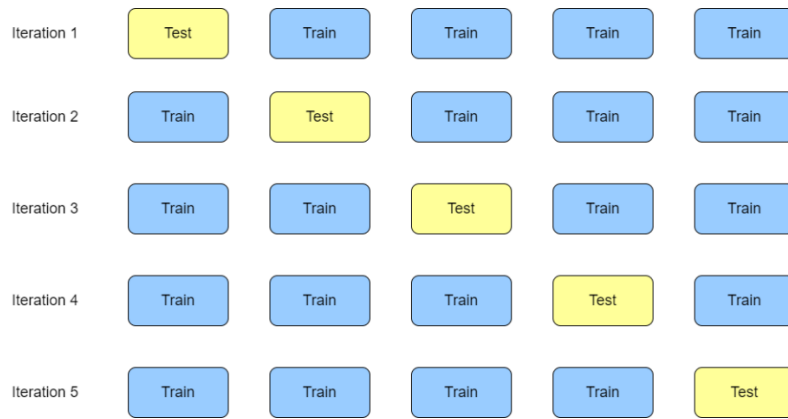
$$tf_{ij} = \frac{fd(i)}{\max fd(j)} \quad (1)$$

*Inversed Document Frequency* (IDF) merupakan pengurangan dari bobot term yang ada pada semua dokumen. Berikut adalah rumus untuk menghitung nilai IDF :

$$idf(t, D) = \log \left( \frac{N}{df(i)} \right) \quad (2)$$

### 3.5 Classification

Tahapan klasifikasi merupakan langkah selanjutnya setelah *preprocessing* dan fitur ekstraksi. Klasifikasi pada penelitian ini menggunakan metode Random Forest dikarenakan algoritma sangat cocok digunakan pada dataset yang besar karena Random Forest memiliki berbagai macam pohon keputusan. Berbagai pohon keputusan akan digabungkan dalam data latih sehingga dapat menghasilkan nilai akurasi yang tinggi. Selain itu penelitian ini menggunakan metode klasifikasi Adaptive Boosting yang lebih efektif sehingga dapat mengurangi underfitting pada metode sebelumnya. Adaptive Boosting juga dapat memberikan bobot yang lebih tinggi yang memungkinkan model untuk fokus prediksi sehingga menghasilkan nilai akurasi yang lebih tinggi.



**Gambar 4 Cross Validation**

Pemodelan ini menggunakan cross Validation dengan nilai k=5 untuk menilai kemampuan generalisasi model dengan meminimalkan overfitting[24]. Cross validation dilakukan setelah split data kemudian model dievaluasi pada k-1 sementara lainnya disimpan. Proses ini diulang hingga semua telah dievaluasi. Setelah proses validasi selesai, pengukuran penilaian akan dihitung dan diringkas dengan menghitung nilai rata rata.

Selanjutnya menggunakan *confusion matrix* untuk mengukur performa dari algoritma klasifikasi yang telah digunakan. Terdapat nilai pembanding pada *confusion matrix*, yaitu *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)*, dan *False Negative (FN)*.

**Table 3 Confusion Matrix**

Kelas Aktual	Kelas Prediksi	
	Positif	Negatif
Positif	TP	FN
Negatif	FP	TN

Berikut merupakan penjelasan pada tiap nilai yang terdapat dalam *confusion matrix* :

- True Positif (TP) : Jumlah data yang diklasifikasikan sebagai positif dan hasil aktual juga positif.
- False Positif (FP) : Jumlah data yang diklasifikasikan sebagai positif, namun hasil aktual negatif.
- True Negatif (TN) : Jumlah data yang diklasifikasikan sebagai negatif dan hasil aktual juga negatif.
- False Negatif (FN) : Jumlah data yang diklasifikasikan sebagai negatif, namun hasil aktual positif.

Setelah mengetahui nilai *confusion matrix* selanjutnya akan menghitung classification report yaitu perhitungan untuk mengetahui *classification report* yang terdiri dari *accuracy*, *Precision*, *Recall*, dan *F1 Score*. Perhitungan *accuracy* merupakan persentase tingkat pada jumlah data yang telah diklasifikasi sebelumnya. Perhitungan *precision* adalah perhitungan klasifikasi antara data yang diminta dengan hasil prediksi oleh model. Perhitungan *recall* adalah perhitungan klasifikasi yang dibagi dengan seluruh data asli yang positif. Dan perhitungan *F1 Score* merupakan metrik evaluasi dari nilai *precision* dan *recall* sebelumnya.

Rumus perhitungan *confusion matrix* adalah sebagai berikut:

Rumus *accuracy* :

$$Accuracy = \frac{TP+TN}{TP+FN+TN+FP} \times 100\%$$



(3)

Rumus *precision* :

$$Precision = \frac{TP}{TP + FP}$$

(4)

Rumus *recall* :

$$Recal = \frac{TP}{TP + FN}$$

(5)

Rumus *f1 score* :


$$F1\ Score = \frac{2 \times precision \times recall}{precision + recall}$$

(6)

## Evaluasi

### 4.1 Hasil Pengujian

Pada sistem analisis sentimen ini, penulis menggunakan dataset sebanyak 3139 data tweet yang berbahasa Indoensia dengan keyword “Bank BCA”. Setelah melalui tahap *preprocessing* diketahui data memiliki 3 sentimen analisis yaitu positif, negatif, dan netral. Dengan rincian pada sentimen negatif memiliki hasil sebesar 15,92% dengan jumlah data 500, untuk sentimen netral sebesar 47,43% dengan jumlah data 1489, dan sentimen positif sebesar 36,63% dengan jumlah data 1150.



**Gambar 5 Diagram Bar Analisis Sentimen**

### 4.2 Random Forest

Tahapan selanjutnya pada penelitian ini adalah mengklasifikasi dengan metode Random Forest, beberapa percobaan klasifikasi telah dilakukan dengan menggunakan Teknik Cross Validation dengan melatih ulang data yang telah dibagi sebelumnya yaitu dengan split data yang dapat dilihat pada tabel 5 sebanyak 5 kali percobaan. Teknik Cross Validation diperlukan untuk memastikan seluruh data di uji dan di latih sehingga mencegah keberuntungan semata pada hasil yang berkualitas. Hasil percobaan dapat dilihat pada tabel x berikut ini :

**Table 4 Hasil Iterasi Cross Validation**

Iterasi	Score(%)
1	75,25%
2	74,62%
3	74,87%
4	78,25%


Pada score yang dihasilkan memiliki nilai rata rata sebanyak 76,46% dengan 5x pelatihan data dengan 5 grup split data yang berbeda. Kemudian akan dilakukan pencarian parameter terbaik menggunakan metode Random Forest pada seluruh dataset dengan menentukan estimasi jumlah pohon dan kedalaman maksimum pada setiap pohon.

**Table 5 Estimator Best Param**

Estimator	Score(%)
100	75.40%
200	76.40%
500	76.50%

Terdapat 3x percobaan untuk menentukan parameter terbaik dengan nilai estimasi 100, 200, 500. Pada percobaan estimasi dengan nilai 100 memiliki score sebanyak 75.40%, berikutnya nilai estimasi 200 memiliki score 76.40%, dan nilai estimasi 500 memiliki score 76,50%. Diketahui bahwa parameter terbaik dengan *maximal deph=none* adalah nilai estimasi 500 dengan score 76.50%.

Kenaikan 0,10% pada nilai estimasi 200 dengan 500 dianggap signifikan karena score tersebut merupakan score tertinggi yang didapat pada parameter tersebut. Parameter dengan nilai 500 menunjukkan kinerja yang lebih baik dibandingkan dengan percobaan dengan parameter lainnya. Dampak dari hasil perbedaan 0,10% akan secara langsung mempengaruhi tingkat akurasi dalam proses klasifikasi pemodelan.



**Gambar 6 Hasil Confusion Matrix**

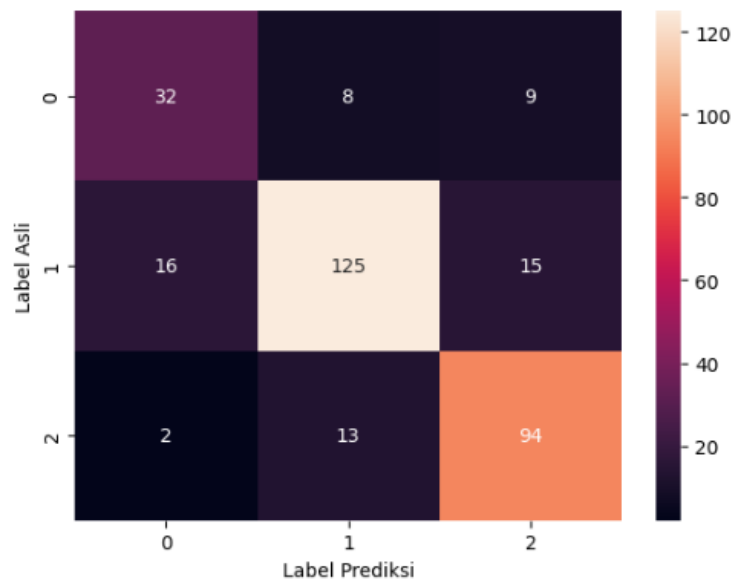
Pada diagram 7, terdapat matriks kebingungan dari Random Forest yang memuat 32 data dari kelas Negative yang berhasil diprediksi sebagai Negative. Selain itu, terdapat 118 data dari kelas Netral yang dengan benar diprediksi sebagai Netral. Di samping itu, 93 data dari kelas Positive juga diprediksi secara akurat sebagai Positive. Namun, terdapat beberapa kesalahan dalam proses prediksi. Sebanyak 21 data dari kelas Negative keliru diprediksi sebagai Netral. Terdapat 8 data dari kelas Netral yang salah prediksi menjadi Negative. Selanjutnya, ada 17 data dari kelas Positive yang salah diprediksi sebagai Netral.

**Table 6 Classification Report Random Forest**

Algorithm	Accuracy(%)	Precision(%)	Recall(%)	F1 Score(%)
Random Forest	77%	73%	75%	74%

Berdasarkan gambar 7 dapat dilihat *confusion matrix* dari metode Random Forest sehingga menghasilkan *classification report* pada tabel 6. Model Random Forest menghasilkan akurasi sebesar 77%, yang berarti model ini dapat memprediksi cukup baik. *Precision* yang dihasilkan pada model adalah 73% yang berarti sekitar 73% dari prediksi positif yang dibuat oleh model adalah benar. *Recall* menghasilkan 75% yang berarti model telah berhasil mengidentifikasi sekitar 75% dari data positif pada dataset. *F1 Score* menghasilkan 74% yang berarti rata-rata dari *precision* dan *recall*. Hasil tersebut merupakan gambaran mengenai performa model klasifikasi Random Forest pada dataset, dengan akurasi yang dihasilkan cukup tinggi serta keseimbangan antara *precision* dan *recall* yang baik.

#### 4.3 Adaptive Boosting



**Gambar 7 Confusion Matrix Adaptive Boosting**

Pada diagram 8 terdapat matriks kebingungan dari Adaptive Boosting yang memuat 32 data dari kelas Negative yang secara tepat diprediksi sebagai Negative. Terdapat 125 data dari kelas Netral yang akurat diprediksi sebagai Netral. Selain itu, terdapat 94 data dari kelas Positive yang diprediksi dengan benar sebagai Positive. Meskipun demikian, terdapat beberapa kesalahan dalam prediksi. Sebanyak 16 data dari kelas Negative salah prediksi menjadi Netral. Selanjutnya, terdapat 2 data dari kelas Negative yang keliru diprediksi sebagai Positive. Di sisi lain, 8 data dari kelas Netral salah ditebak sebagai Negative.

Hasil klasifikasi pada metode Adaptive Boosting memiliki nilai akurasi sebesar 80%. Berikut adalah tabel *classification report* pada Adaptive Boosting.

**Table 7 Classification Report AdaBoost**

Algorithm	Accuracy(%)	Precision(%)	Recall(%)	F1 Score(%)
Adaptive Boosting	80% (+3)	76%	77%	77%

Pada tabel 8 menunjukkan hasil *classification report* dari model Adaptive Boosting, pada tingkat akurasi menghasilkan 80% yang menunjukkan kenaikan 2% dari model sebelumnya. Pada *precision* menghasilkan 76% yang berarti sekitar 76% diprediksi positif oleh model adalah benar. *Recall* menghasilkan presentase sebesar 77% yang berarti sekitar 77% model mengidentifikasi data positif yang ada telah berhasil. *F1 Score* menghasilkan 77% yang merupakan rata-rata dari hasil *precision* dan *recall*. Pada pemodelan klasifikasi dengan menggunakan Adaptive Boosting memiliki tingkat akurasi lebih tinggi, hal ini dikarenakan Adaptive Boosting dapat menoleransi jika terjadinya noise pada data.

#### 4.4 Perbandingan Kinerja Pemodelan

Proses selanjutnya adalah membandingkan antar kedua hasil pemodelan yang telah dilakukan sebelumnya untuk mengetahui pemodelan terbaik berdasarkan *classification report*. Tabel perbandingan terdiri dari hasil *accuracy*, *precision*, *recall* dan *f1 score*.

**Table 8 Perbandingan Classification Report**

Algorithm	Accuracy(%)	Precision(%)	Recall(%)	F1 Score(%)
Random Forest	77%	73%	75%	74%
Adaptive Boosting	80% (+3)	76% (+3)	77% (+2)	77% (+3)

Berdasarkan tabel 9 tersebut menunjukkan bahwa algoritma *Adaptive Boosting* memiliki performa yang lebih baik dibandingkan dengan algoritma *Random Forest* dalam segi *accuracy*, *precision*, *recall* dan *f1 Score*. Namun penting untuk diingat bahwa pemilihan algoritma harus disesuaikan dengan karakteristik data yang ada.

## 5. Kesimpulan

Penelitian ini dibangun menggunakan metode klasifikasi Random Forest dan Boosting dengan tujuan mengetahui tingkat akurasi nilai sentimen pada suatu topik. Metode Random Forest dan Boosting diajukan sebagai salah satu metode pendekatan yang dapat digunakan dalam analisis sentimen. Sistem analisis menggunakan dataset sebanyak 3139 data tweet yang berbahasa Indoensia dengan keyword “Bank BCA”, Pengujian ini melakukan split data untuk memudahkan proses analisis dengan membagi menjadi data *train* dan data *test* dengan rasio perbandingan 1:9. Setelah proses klasifikasi dapat disimpulkan bahwa algoritma Adaptive Boosting memiliki tingkat akurasi yang lebih tinggi yaitu 80% sedangkan algoritma Random Forest memiliki tingkat akurasi 77%. Terbukti bahwa algoritma Adaptive Boosting cukup baik dalam klasifikasi analisis sentimen karena Random Forest membangun model dengan banyak pohon secara independen sehingga memiliki resiko lebih rentan pada dataset.

Saran yang diusulkan untuk penelitian selanjutnya adalah menambahkan dataset dengan topik yang sesuai dengan penelitian, eksplorasi penggunaan teknik ekstraksi fitur lanjutan seperti word2vec atau Doc2Vec selain TF-IDF, dan mencoba model *Boosting* lainnya untuk melihat performa yang berbeda pada model *Boosting*.

## Daftar Pustaka

- [1] S. Rizal and Munawir, "Pengaruh kepuasan nasabah terhadap menggunakan mobile banking (m-banking) pada bank BCA cabang Banda Aceh," *J. EMT KITA*, vol. 1, no. 2, pp. 68–78, 2017.
- [2] Ankit and N. Saleena, "An Ensemble Classification System for Twitter Sentiment Analysis," *Procedia Comput. Sci.*, vol. 132, no. Iccids, pp. 937–946, 2018, doi: 10.1016/j.procs.2018.05.109.
- [3] I. D. Onantya, Indriati, and P. P. Adikara, "Analisis Sentimen Pada Ulasan Aplikasi BCA Mobile Menggunakan BM25 Dan Improved K-Nearest Neighbor," *Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 3, no. 3, pp. 2575–2580, 2019.
- [4] P. Wahyuningtias, H. W. Utami, U. A. Raihan, and H. N. Hanifah, "Comparison Of Random Forest And Support Vector Machine Methods On Twitter Sentiment Analysis ( Case Study : Internet Selebgram Rachel Vennya Escape From Quarantine ) Perbandingan Metode Random Forest Dan Support Vector Machine Pada Analisis Sentimen Twitt," *Jutif*, vol. 3, no. 1, pp. 141–145, 2022.
- [5] N. Ainiyah, "Remaja Millennial dan Media Sosial: Media Sosial Sebagai Media Informasi Pendidikan Bagi Remaja Millennial," *J. Pendidik. Islam Indones.*, vol. 2, no. 2, pp. 221–236, 2018, doi: 10.35316/jpii.v2i2.76.
- [6] O. Dwiraswati and K. N. Siregar, "Analisis Sentimen Pada Twitter Terhadap Penggunaan Antibiotik Di Indonesia Dengan Naive Bayes Classifier," *Media Inf.*, vol. 15, no. 1, pp. 1–9, 2019, doi: 10.37160/bmi.v15i1.232.
- [8] I. A. Rahmi, F. M. Afendi, and A. Kurnia, "Metode AdaBoost dan Random Forest untuk Prediksi Peserta JKN-KIS yang Menunggak," *Jambura J. Math.*, vol. 5, no. 1, pp. 83–94, 2023, doi: 10.34312/jjom.v5i1.15869.
- [9] R. Dwi Lingga P., C. Fatichah, and D. Purwitasari, *Deteksi Gempa Berdasarkan Data Twitter Menggunakan Decision Tree, Random Forest, dan SVM*, vol. 6, no. 1. 2017.
- [10] M. A. A. Jihad, Adiwijaya, and W. Astuti, "Analisis sentimen terhadap ulasan film menggunakan algoritma random forest," *e-Proceeding Eng.*, vol. 8, no. 5, pp. 10153–10165, 2021.
- [11] Kurnia, I. Purnamasari, and D. D. Saputra, "Analisis Sentimen Dengan Metode Naive Bayes, SMOTE Dan Adaboost Pada Twitter Bank BTN," *J. JTik (Jurnal Teknol. Inf. dan Komunikasi)*, vol. 7, no. 2, pp. 235–242, 2023, doi: 10.35870/jtik.v7i3.707.
- [12] D. Sepri, P. Algoritma, N. Bayes, U. Analisis, K. Penggunaan, and A. Bank, "Media Cetak," *J. Comput. Syst. Informatics (JoSYC)*, vol. 2, no. 1, pp. 135–139, 2020.
- [13] F. Gunawan, M. A. Fauzi, and P. P. Adikara, "Analisis Sentimen Pada Ulasan Aplikasi Mobile Menggunakan Naive Bayes dan Normalisasi Kata Berbasis Levenshtein Distance (Studi Kasus Aplikasi BCA Mobile)," *Syst. Inf. Syst. Informatics J.*, vol. 3, no. 2, pp. 1–6, 2017, doi: 10.29080/systemic.v3i2.234.
- [14] A. Primajaya and B. N. Sari, "Random Forest Algorithm for Prediction of Precipitation," *Indones. J. Artif. Intell. Data Min.*, vol. 1, no. 1, p. 27, 2018, doi: 10.24014/ijaidm.v1i1.4903.
- [15] G. A. Sandag, "Prediksi Rating Aplikasi App Store Menggunakan Algoritma Random Forest," *CogITO Smart J.*, vol. 6, no. 2, pp. 167–178, 2020, doi: 10.31154/cogito.v6i2.270.167-178.
- [16] S. Khairunnisa, A. Adiwijaya, and S. Al Faraby, "Pengaruh Text Preprocessing terhadap Analisis Sentimen Komentar Masyarakat pada Media Sosial Twitter (Studi Kasus Pandemi COVID-19)," *J. Media Inform. Budidarma*, vol. 5, no. 2, p. 406, 2021, doi: 10.30865/mib.v5i2.2835.
- [17] B. S. Yang, X. Di, and T. Han, "Random forests classifier for machine fault diagnosis," *J. Mech. Sci. Technol.*, vol. 22, no. 9, pp. 1716–1725, 2008, doi: 10.1007/s12206-008-0603-6.
- [18] A. Budianto, R. Ariyuana, and D. Maryono, "Perbandingan K-Nearest Neighbor (Knn) Dan Support Vector Machine (Svm) Dalam Pengenalan Karakter Plat Kendaraan Bermotor," *J. Ilm. Pendidik. Tek. dan Kejuru.*, vol. 11, no. 1, p. 27, 2019, doi: 10.20961/jiptek.v11i1.18018.
- [19] J. W. Fernanda, "Boosting Neural Network dan Boosting Cart," vol. 2, no. 2, pp. 33–49, 2012.
- [20] J. Sanjaya, E. Renata, V. E. Budiman, F. Anderson, and M. Ayub, "Prediksi Kelalaian Pinjaman Bank Menggunakan Random Forest dan Adaptive Boosting," *J. Tek. Inform. dan Sist. Inf.*, vol. 6, no. 1, pp. 50–60, 2020, doi: 10.28932/jutisi.v6i1.2313.
- [21] A. Kukkar, R. Mohana, A. Nayyar, J. Kim, B. G. Kang, and N. Chilamkurti, "A novel deep-learning-based bug severity classification technique using convolutional neural networks and random forest with boosting," *Sensors (Switzerland)*, vol. 19, no. 13, 2019, doi: 10.3390/s19132964.
- [22] C. S. Sriyano and E. B. Setiawan, "Pendeteksian Berita Hoax Menggunakanfile:///D:/SEMESTER\_8/ref/113-345-1-PB.pdfan Naive Bayes Multinomial Pada Twitter dengan Fitur Pembobotan TF-IDF," *e-Proceeding Eng.*, vol. 8, no. 2, pp. 3396–3405, 2021.