

Perbandingan Metode Decision Tree dan Support Vector Machine untuk Analisis Sentimen pada Instagram Mengenai Kinerja PSSI

Muhammad Fadli Asshiddiqi¹, Kemas Muslim Lhaksana²

^{1,2}Fakultas Informatika, Universitas Telkom, Bandung

¹mfadlimaska@students.telkomuniversity.ac.id, ²kemasmuslim@telkomuniversity.ac.id

Abstrak

Pada tahun 2018 hingga pertengahan tahun 2019 ramai dibicarakan mengenai permasalahan sepak bola Indonesia yang berujung kekecewaan masyarakat terhadap persatuan sepak bola seluruh Indonesia (PSSI) tetapi pada akhir tahun 2019 PSSI membuktikan kinerjanya dan mendapatkan prestasi, dengan kondisi tersebut dipastikan banyak opini masyarakat akan bermacam-macam terhadap PSSI pada media sosial. Dari banyaknya opini tersebut akan menjadi sebuah data yang bisa menentukan kepuasan masyarakat terhadap kinerja PSSI apakah hasilnya cenderung positif atau negatif dengan cara melakukan sentimen analisis. Untuk menunjang sentimen analisis diperlukan Algoritma klasifikasi, algoritma pada penelitian ini menggunakan Decision Tree dan Support Vector Machine. Hasil komposisi data terbaik untuk melakukan pengujian adalah 80%:20% dengan mendapatkan hasil nilai akurasi 87.45%, precision 87.72%, recall 91.74% dan F1-Score 89.69% pada Decision Tree dengan TF-IDF sedangkan untuk Support Vector Machine dengan TF-IDF komposisi data terbaik adalah 80%:20% mendapatkan hasil nilai akurasi akurasi 94.36%, precision 96.78%, recall 94.30% dan F1-Score 95.53%. Maka pada kasus ini sentiment analisis pada komentar instagram akan lebih baik jika menggunakan Support Vector Machine (SVM) dengan TF-IDF.

Kata kunci: decision tree, support vector machine, PSSI, term weighting

Abstract

In 2018 until mid-2019 there were many discussions about the problem of Indonesian football which led to public disappointment with the football association of Indonesia (PSSI) but at the end of 2019 PSSI proved its performance and gained achievements, with these conditions it is certain that many opinions about PSSI will vary on social media. From the many opinions, it will become data that can determine public satisfaction with PSSI's performance whether the results tend to be positive or negative by conducting sentiment analysis. To support the sentiment analysis, a classification algorithm is needed. The algorithm in this study uses a Decision Tree and a Support Vector Machine. The results of the best data composition for testing are 80%: 20% by getting an accuracy value of 87.45%, 87.72% precision, 91.74% recall and 89.69% F1-Score on the Decision Tree with TF-IDF while for Support Vector Machine with TF-IDF The best data composition is 80%: 20% get an accuracy value of 94.36% accuracy, 96.78% precision, 94.30% recall and 95.53% F1-score. So in this case the sentiment analysis on instagram comments would be better if you use the Support Vector Machine (SVM) with TF-IDF.

Keywords: decision tree, support vector machine, PSSI, term weighting

1. Pendahuluan

Latar Belakang

Sepak bola merupakan salah satu olah raga yang banyak digemari oleh masyarakat Indonesia. Menurut penelitian yang dilakukan oleh Nielsen Sport, sepak bola Indonesia menepati posisi kedua didunia sebagai negara yang memiliki minat atau ketertarikan terhadap sepakbola sebesar 77% penduduk Indonesia [1]. Selain itu, 6 klub sepak bola Indonesia masuk dalam 200 klub terpopuler di dunia menurut The Global Digital Football Benchmark. Berdasarkan fakta pencapaian tersebut maka sepak bola sudah sangat melekat sekali di masyarakat Indonesia, kepedulian dan harapan masyarakat terhadap pesepak bolaan Indonesia sangatlah tinggi.

Pada tahun 2018 hingga pertengahan tahun 2019 ramai dibicarakan mengenai permasalahan dan kontroversi sepak bola Indonesia yang berujung kekecewaan beberapa masyarakat terhadap persatuan sepak bola seluruh Indonesia (PSSI). Terdapat beberapa kasus sepak bola di Indonesia yaitu mengenai kasus mafia bola yang dimana Satgas anti mafia menerima 338 laporan terkait dugaan pengaturan skor di Liga 2 dan Liga 3 [2], prestasi buruk tim nasional, gagal memperpanjang kontrak Luis Milla sebagai pelatih, pertikaian supporter dan rangkap jabatan ketua umum PSSI. Tetapi pada akhir tahun 2019, PSSI membuktikan kinerjanya diantaranya terpilihnya Indonesia menjadi tuan rumah piala dunia umur 20 pada tahun 2021 dan tim nasional Indonesia menjadi juara dua AFF 2019 melaju pada ajang AFC.

Dengan adanya kontroversi/polemik dan pencapaian tersebut dipastikan opini masyarakat akan beragam. Pada saat ini kemajuan teknologi memudahkan masyarakat menyampaikan opini pada *platform* social media salah satunya Instagram. Instagram merupakan layanan berbasis internet sekaligus jejaring sosial untuk berbagi cerita via gambar digital dan video. Indonesia merupakan negara pemakai instagram terbanyak menduduki peringkat ke empat didunia sebanyak 73 juta pengguna atau 27% dari total populasi di Indonesia pada juli 2020 [3]. Pada saat ini, instgaram seringkali digunakan oleh pengguna untuk menyampaikan sebuah opini terhadap lembaga, tokoh publik, penyedia layanan, politik, perusahaan, pemerintah dan badan kepengurusan.

Penyampaian opini mengenai sepak bola salah satunya disampaikan melalui kolom komentar pada Instagram akun @pssi. Opini tersebut akan menjadi sebuah data banyak yang bisa menentukan kepuasan masyarakat terhadap kinerja PSSI apakah hasilnya positif atau negatif. Karna opininya sangat banyak dan akan sulit jika di lakukan secara manual, maka dibutuhkan metode analisis sentiment secara otomatis menggunakan sentimen analisis. Analisis sentimen atau biasa disebut juga opinion mining adalah bidang studi yang menganalisis opini, sentimen, evaluasi, sikap, dan emosi terhadap suatu entitas [4].

Pada penelitian yang sudah dilakukan mengenai analisis sentiment. Penelitian yang dilakukan oleh Bo Pang yang berjudul *Thumbs up? Sentiment Classification using Machine Learning Techniques* hasil penelitian menggunakan beberapa ekstraksi fitur, yaitu unigram, gabungan unigram dengan bigram, gabungan unigram dengan part of speech, adjective, dan gabungan unigram dengan posisi. Didapatkan hasil akurasi yang paling baik dengan metode *Support Vector Machine* dikombinasikan dengan unigram sebesar 82.9% [5]. penelitian yang dilakukan oleh Winda Christina Widyaningtyas yang berjudul *Klasifikasi Sentiment Analisis pada Review Film Berbahasa Inggris dengan Menggunakan Metode Doc2Vec dan Support Vector Machine (SVM)* hasil penelitian algoritma *Doc2Vec* dan *SVM* yang digunakan pada kasus review film memiliki nilai *F1-Measure* sebesar 54.1872% dan hasil tertinggi akurasi pada dataset, pada karnel polynominal dengan akurasi 54.19% [6]. Seturusnya penelitian yang dilakukan oleh Novita Dewi Susanti, pada judul paper *Uji Perbandingan Akurasi Analisis Sentimen Pariwisata menggunakan Algoritma Support Vektor Machine dan Naive Bayes* hasil penelitiannya menghasilkan perbandingan antara precision, recall dan terakhir akurasi. Hasil yang didapat precision pada *Support Vector Machine* 87,25% sedangkan *Naive Bayes* adalah 65,97%. Hasil dari *Recall* pada *Naive Bayes* adalah 96,39%, untuk *Support Vector Machine* 80,60%. Terakhir hasil akurasi yang didapatkan pada *Support Vector Machine* 76,47% dan *Naive Bayes* 65,78% [7].

Berdasarkan penelitian yang telah dilakukan sebelumnya penulis tertarik untuk melakukan penelitian analisis sentimen dengan menerapkan perbandingan algoritma *Decision Tree* dan *Support Vector Machine (SVM)*. Alasan penggunaan dua algoritma tersebut yaitu *Support Vector Machine (SVM)* merupakan salah satu metode klasifikasi untuk menentukan fungsi pemisah yang optimal dan mempunyai generalisasi data yang tinggi[9]. Untuk *Decision Tree* adalah suatu model prediksi yang menggunakan struktur pohon merupakan salah satu metode klasifikasi yang populer yang sering digunakan secara praktis dan mempunyai keunggulan memiliki kekuatannya mengenai konsep yang jelas sehingga dapat mudah untuk dipahami dan mengimplementasikannya mudah dengan menggunakan algoritma rekursif [8].

Topik dan Batasannya

Untuk topik dan batasan pembuatan Tugas Akhir ini adalah

1. Menggunakan teks komentar dalam berbahasa Indonesia.
2. Teks yang di analisis berasal dari komentar foto pada akun instagram @pssi (Persatuan Sepak Bola Seluruh Indonesia),
3. Menggunakan *term weighting* TF-IDF, TF dan TF-RF untuk menunjang algoritma klasifikasi hasil terbaik.
4. Terakhir berfokus pada hasil klasifikasi yang dihasilkan dengan menggunakan metode *Decision Tree* dan *Support Vector Machine (SVM)*.

Tujuan

Tujuan pembuatan Tugas Akhir ini adalah.

1. Menguji dan menganalisis performansi klasifikasi *Decision Tree* dan *Support Vector Machine* pada setiap *term weighting*.
2. Mengetahui hasil perbandingan Algoritma *Decision Tree* dan *Support Vector Machine* pada setiap *term weighting*.
3. Mengetahui hasil sentimen analisis pada komentar instagram atas kinerja persatuan sepak bola seluruh Indonesia (PSSI).

2. Studi Terkait

2.1 Text Mining


Text mining adalah proses ekstraksi pola (informasi dan pengetahuan yang berguna) dari sejumlah besar sumber data tak terstruktur. Pada text mining memiliki suatu tujuan dan menggunakan proses yang sama dengan data mining tetapi memiliki inputan yang beda karena data yang digunakan merupakan data yang tidak atau kurang struktur tetapi untuk penambangan data biasanya data yang terstruktur. Tahapan paling umum dalam text mining adalah text preprocessing dan *term weighting* [9]. Tujuan pada text mining merupakan untuk mencari dan mendapatkan informasi yang bisa berguna dari dokumen tertentu.

2.2 Analisis Sentimen

Opini dan konsep terkait seperti sentimen, evaluasi, sikap, dan emosi adalah subyek dari studi analisis sentimen dan opinion mining. Analisis sentimen selalu berkembang untuk menjadi suatu penelitian dalam pengolahan bahasa alami karena dipengaruhi oleh adanya pembelajaran mengenai text mining, penambangan data, penambangan web, dan pembelajaran mesin. Untuk saat ini hampir setiap perusahaan atau lembaga memakai sentimen analisis untuk meningkatkan bisnis dan keperluan lainnya [10]. Analisis sentimen atau biasa disebut juga opinion mining adalah bidang studi yang menganalisis opini, sentimen, evaluasi, sikap, dan emosi terhadap suatu entitas [4]. Entitas tersebut dapat berupa produk, jasa, organisasi, individu, masalah, peristiwa atau sebuah topik. Analisis sentimen hampir sering terpakai dan diperlukan pada setiap saat yang dipergunakan untuk menganalisis suatu produk, konsumen, jasa, kesehatan, industri dan keuangan.

3. Sistem yang Dibangun

Pada metode penelitian ini dibagi menjadi beberapa tahap, diawali dengan scraping data dilanjutkan dengan pebelan data yang akan dibagi menjadi dua kelas. Tahapan selanjutnya dilakukan preprocessing agar data lebih terstruktur dengan dilakukan beberapa proses yaitu *case folding*, *cleansing*, *stopward removal*, *word repair*, *stemming* dan *tokenizing*. Setelah data terstruktur dilakukan *term weighting* menggunakan beberapa metode agar mengetahui *term weighting* yang cocok untuk setiap algoritma klasifikasi, *term weighting* yang digunakan yaitu TF, TF-IDF dan TF-RF. Selanjutnya masuk tahap pembagian data ke dalam data latih dan data uji, dilanjutkan mengklasifikasi data menggunakan algoritma *Support Vector Machine* dan *Decision Tree*. Terakhir Melakukan evaluasi yang menghasilkan nilai akurasi, *recall*, *precion* dan *F1 score*. Proses diatas digambarkan dalam Gambar 1.



Gambar 1. Alur Metode Penelitian

3.1. Pengumpulan Data

Proses pengumpulan data mengambil dari media sosial Instagram pada komentar foto dengan menggunakan Octoparse. Octoparse adalah aplikasi scraping untuk mendapatkan informasi yang sedang dicari pada suatu website. Media sosial Instagram dipilih mengingat Instagram di Indonesia merupakan media sosial yang menempati posisi ke empat sebagai negara pemakai terbanyak di dunia sebanyak 73 juta pengguna pada juli 2020 [3]. Pengambilan data komentar mempertimbangkan dengan isi dan maksud gambar pada photo agar relevan dengan penelitian ini. Komentar diambil pada akun @officialpssi dengan foto yang berkaitan dengan kinerja PSSI yang berisikan gambar Ketua Umum PSSI Mochamad Iriawan, proses pekerjaan suatu proyek, perjalanan dinas, penghargaan tim nasional atau pssi, kemenpora dan kerja sama lembaga.

3.2. Pelabelan Data

Pelabelan data dilakukan secara manual melibatkan annotator sebagai narasumber mengenai sepak bola, pengelompokan komentar dan memberi label pada beberapa data. Setelah dilakukan review dan pelabelan data, diputuskan data dibagi menjadi dua kelas yaitu sentiment positif dan sentiment negative dengan alasan sentiment netral tidak terlalu banyak dan ditakutkan menjadi data ambigu ketika diterapkan sentiment netral. Data yang dilabelkan hanya 200 data yang sama per annotator yang terdiri dari tiga orang annotator tujuannya untuk mendapatkan sampling pelebelan data negatif / positif. Setelah pelebalan penulis menentukan hasil label dari tiga orang annotator. Komentar positif berisi pemberian dukungan terhadap PSSI, mengapresiasi kinerja PSSI, kebanggaan kepada tokoh PSSI sedangkan komentar negatif berisi cacik maki / kata kasar terhadap PSSI, harapan terhadap kinerja PSSI, kekecewaan terhadap kinerja PSSI, kebanggaan kepada tokoh PSSI. Hasil label data secara manual sebanyak 2750 data maka dihasilkan 1714 kelas negatif dan 1043 kelas positif. Keterangan mengenai annotator terdapat pada Tabel 1.

Tabel 1. Annotator Pelebelan Data

Annotator	Jurusan	Universitas	Keterangan
Annotator 1	S1 Ilmu Komunikasi	Lulusan Telkom University	Tugas Akhir: Fanatisme Komunitas Viking Persib Club
Annotator 2	S1 Informatika	Lulusan Telkom University	Anggota Madridista Sukabumi
Annotator 3	S1 Ilmu Komunikasi	Mahasiswa Universitas Islam Bandung	Anggota Viking Persib

3.3. Preprocessing

1. Case Folding

Case folding merupakan tahap yang paling sederhana dan efektif yang tujuannya mengubah semua menjadi huruf kecil atau lowercase pada sebuah dokumen [11]. Ketika sudah memasuki case folding akan memudahkan dalam pencarian dan mengkonsistenkan huruf pada suatu dokumen.

Tabel 2. Contoh Case Folding

Masukan	Keluaran
Mending senior tidak usah ikut event pak, saya masyarakat biasa yang sangat antusias kalo ada timnas main lawan manapun. Tapi kalo udah kaya gini, main gada semangat, gada motivasi buat menang. Cuma bikin malu Indonesia di Mata Negara lain pak:) saya kecewa, sedih, miris :)	mending senior tidak usah ikut event pak, saya masyarakat biasa yang sangat antusias kalo ada timnas main lawan manapun. tapi kalo udah kaya gini, main gada semangat, gada motivasi buat menang. cuma bikin malu indonesia di mata negara lain pak:) saya kecewa, sedih, miris :)

2. Data Cleaning

Data cleaning adalah proses pembersihan kata dengan menghilangkan delimiter tag, html, angka, symbol, koma (,), titik (.), dan tanda baca lainnya. Tujuan *data cleaning* agar data tidak terlalu banyak noise pada dokumen.

Tabel 3. Contoh Data Cleaning

Masukan	Keluaran
mending senior tidak usah ikut event pak, saya masyarakat biasa yang sangat antusias kalo ada timnas main lawan manapun. Tapi kalo udah kaya gini, main gada semangat, gada motivasi buat menang. Cuma bikin malu Indonesia di Mata Negara lain pak:) saya kecewa, sedih, miris :)	mending senior tidak usah ikut event pak saya masyarakat biasa yang sangat antusias kalo ada timnas main lawan manapun tapi kalo udah kaya gini main gada semangat gada motivasi buat menang cuma bikin malu indonesia di mata negara lain pak saya kecewa sedih miris

3. Tokenizing

Tokenizing adalah proses pemotongan dokumen menjadi bagi-bagian kata atau karakter yang sesuai dengan kebutuhan sebuah system.

Tabel 4. Contoh Tokenizing

Masukan	Keluaran
mending senior tidak usah ikut event apa pak saya masyarakat biasa yang sangat antusias kalo ada timnas main lawan manapun tapi kalo udah kaya gini main gada semangat gada motivasi buat menang cuma bikin malu indonesia di mata negara lain pak saya kecewa sedih miris	'mending','senior','tidak','usah','ikut','event','pak','saya','masyarakat','biasa','yang','sangat','antusias','kalo','ada','timnas','main','lawan','manapun','tapi','kalo','udah','kaya','gini','main','gada','semangat','gada','motivasi','buat','menang','cuma','bikin','malu','indonesia','di','mata','negara','lain','pak','saya','kecewa','sedih','miris'

4. Word Repair

Word repair adalah proses penanganan kata singkatan, salah ketik dan tidak baku menjadi sesuai kamus besar Bahasa Indonesia. Tahap ini sangat bisa berpengaruh dalam proses selanjutnya. Contoh word repair pada kata "batre", "batere", dan "btrai" yang akan ditransformasi menjadi kata "baterai".

Tabel 5. Contoh Word Repair

Masukan	Keluaran
'mending','senior','tidak','usah','ikut','event','pak','saya','masyarakat','biasa','yang','sangat','antusias','kalo','ada','timnas','main','lawan','manapun','tapi','kalo','udah','kaya','gini','main','gada','semangat','gada','motivasi','buat','menang','cuma','bikin','malu','indonesia','di','mata','negara','lain','pak','saya','kecewa','sedih','miris'	lebih baik senior tidak usah ikut event pak saya masyarakat biasa yang sangat antusias kalau ada tim nasional main lawan manapun tapi kalau sudah kaya begini main tidak ada semangat tidak ada motivasi buat menang hanya buat malu indonesia mata negara lain pak saya kecewa sedih miris

5. Stopword Removal

Stopword Removal adalah proses menghilangkan karakter, tanda baca, serta kata-kata umum yang tidak memiliki makna atau informasi yang dibutuhkan. Contoh kata yang tidak memiliki makna misal "dan", "atau", "tapi" dan lainnya.

Tabel 6. Contoh Stopword Removal

Masukan	Keluaran
lebih baik senior tidak usah ikut event pak saya masyarakat biasa yang sangat antusias kalau ada tim nasional main lawan manapun tapi kalau sudah kaya begini main tidak ada semangat tidak ada motivasi buat menang hanya buat malu indonesia mata negara lain pak saya kecewa sedih miris	lebih baik senior usah ikut event pak masyarakat biasa sangat antusias kalau tim nasional main lawan manapun kalau kaya begini main semangat motivasi buat menang buat malu indonesia mata negara pak kecewa sedih miris

6. Stemming

Stemming adalah proses menghapus imbuhan, awalan, akhiran yang bertujuan untuk mengubah katakata sesuai dengan kata dasarnya. Proses ini diperlukan untuk mengelompokkan kata-kata yang memiliki kata dasar dan arti yang serupa namun memiliki bentuk penulisan yang berbeda [12]. Contoh pada pengelompokkan kata-kata tersebut adalah kata "membuat", "berbuat", dan "membuatkan" yang akan ditransformasi menjadi kata "buat".

Tabel 7. Contoh Stemming

Masukan	Keluaran
lebih baik senior usah ikut event pak masyarakat biasa sangat antusias kalau tim nasional main lawan manapun kalau kaya begini main semangat motivasi buat menang buat malu indonesia mata negara pak kecewa sedih miris	lebih baik senior usah ikut event pak masyarakat biasa sangat antusias kalau tim nasional main lawan mana kalau kaya begini main semangat motivasi buat menang buat malu indonesia mata negara pak kecewa sedih miris

3.4. Term weighting

1. Term Frequency (TF)

Term Frequency adalah kemunculan frekuensi munculnya kata sama pada dokumen. Dengan metode ini, nilai kontribusi (bobot) suatu term pada suatu dokumen adalah sama dengan jumlah munculnya term tersebut pada dokumen. rumus TF dapat dilihat pada persamaan 1.

$$W(t,d) = TF(t,d) \quad (1)$$

Dimana $TF(d,t)$ adalah frekuensi kemunculan term t pada dokumen d .

2. Term Frequency – Inverse Document Frequency (TF.IDF)

TF-IDF adalah salah satu metode pembobotan sebuah kata didalam sistem pencarian informasi. TF-IDF metode yang menggabungkan *Term Frequency* (TF) dan *Inverse Document Frequency* (IDF). Term Frequency adalah kemunculan frekuensi munculnya kata sama pada dokumen. Inverse Document Frequency banyaknya koleksi dokumen yang bersangkutan mengandung kata tertentu [13,14]. Rumus IDF dapat terlihat pada persamaan 2 sedangkan TF-IDF dapat dilihat pada persamaan 3.

$$IDF(t) = \log(N/df(t)) \quad (2)$$

$$TF - IDF = TF(t,d) \times IDF(t) \quad (3)$$

Dengan $TF(t,d)$ adalah frekuensi munculnya term t pada dokumen d , N adalah jumlah kumpulan dokumen, $df(t)$ adalah jumlah dokumen yang mengandung term t .

3. Term Frequency – Relevance Frequency (TF.RF)

Relevan frequency adalah salah satu metode pembobotan yang pada pemberian bobot mempertimbangkan relevansi dari sebuah dokumen untuk term yang sering muncul dalam kaitan tertentu. Pada dasarnya RF hanya akan meningkatkan pada weight dari terms salah satu kategori yaitu positif sementara pada bobot terms dengan kategori negatif akan semakin berkurang [15,16] .

$$TFRF = TF(d, t) \times \log \left(2 \frac{a}{\max(1,C)} \right) \quad (4)$$

Dengan $TF(t,d)$ adalah frekuensi munculnya term t pada dokumen d , a adalah umlah dokumen bukan kategori tertentu yang mengandung term t , c jumlah dokumen dalam kategori tertentu yang mengandung term t .

3.5. Klasifikasi

1. Decision Tree

Decision tree adalah suatu model prediksi menggunakan struktur pohon untuk mencari dan membuat keputusan yang memecahkan suatu masalah dengan mempertimbangkan berbagai faktor yang ada pada lingkup masalah tersebut. *Decision tree* merupakan salah satu metode klasifikasi populer yang sering digunakan secara praktis. Pada metode ini berusaha menemukan model klasifikasi tahan akan derau. *decision tree* memiliki beberapa algoritma salah satunya yang populer yaitu *Iterative Dychotomizer version* (ID3) [9].

Algoritma ID3 membangun sebuah model klasifikasi yang berupa pohon keputsan secara top-down (dari atas ke bawah). Cara kerjanya dengan mengevaluasi pada semua atribut menggunakan suatu ukuran statistik berupa information gain yang dipergunakan untuk mengukur efektifitas pada suatu atribut dalam mengkalsifikasi sampel data. ID3 termasuk pada *decision tree* learning yang bekerja dengan cara melakukan pencarian secara rakus (greedy) sehingga dapat dimungkinkan mendapat hasil tidak optimal tetapi memberikan solusi yang mendekati nilai optimum dalam waktu yang cukup cepat. Pengaplikasian menggunakan sebuah fungsi rekursif yang dimana memanggil dirinya sendiri. Dalam algoritma ini dibutuhkan nilai Entropy dan Gain. Entropy adalah suatu parameter untuk mengukur jumlah keberagaman atau keberbedaan dalam sebuah himpunan data. Gain adalah prolehan informasi sebagai ukuran efektifitas terhadap suatu atribut.

$$Entropy(S) = \sum_{i=1}^n - p_i \times \log_2 p_i \quad (5)$$

$$Gain(S,A) = S - \sum_{i=1}^n \frac{|S_i|}{|S|} \times S_i \quad (6)$$

dengan S merupakan nilai Entropy, p_i jumlah yang memiliki nilai positif atau negatif pada kumpulan data untuk sifat tertentu, Gain (S, A) adalah hasil informasi yang berasal dari output data yang dikelompokkan ke dalam atribut A , S_i adalah subset dari nilai Entropy yang mempunyai nilai i , S adalah subset dari nilai Entropy.

Decision tree memiliki kekuatan dan kelemahan. Pada metode *decision tree* memiliki kekuatannya mengenai konsep yang jelas sehingga dapat mudah untuk dipahami dan mengimplementasikannya mudah dengan menggunakan algoritma rekursif. sedangkan kelemahannya yaitu sulitnya diaplikasikan pada himpunan data yang sangat besar dan mudah mengalami overfit karena proses pelatihan greedy yang tidak menjamin menghasilkan pohon keputusan dalam kondisi yang terbaik [9].

2. Support Vector Machine

Support Vector Machine diperkenalkan oleh Vapnik sebagai suatu teknik klasifikasi yang efisien untuk nonlinier pada tahun 1992. Konsep SVM mirip dengan perceptron pada ANN, yaitu menemukan hyperplane yang memisahkan suatu himpunan data ke dalam dua kelas secara linear. *Hyperplane* akan menemukan titik optimum ketika hyperplane tersebut berjarak tepat pada tengah-tengah kelas yang dipisahkan [9].

Support Vector Machine memiliki kelebihan dan kelemahan. Kelebihan mempunyai kemampuan generalisasi data yang tinggi, mampu menghasilkan model klasifikasi yang baik meskipun dilatih dengan himpunan data yang relative sedikit hanya dengan pengaturan parameter yang sederhana dan relative mudah diimplementasikan. Kelemahan sulit diaplikasikan untuk himpunan data dengan sampel dan dimensi yang sangat besar dan umumnya diformulasikan untuk menyelesaikan masalah klasifikasi dua kelas.

3.6. Confusion Matrix

Confusion matrix yaitu sebuah tabel yang terdiri atas banyaknya baris data uji yang diprediksi benar dan tidak benar oleh model klasifikasi, tabel ini diperlukan untuk menentukan kinerja suatu model klasifikasi.

1. *True Positive* (TP) : Ketika kelas yang diprediksi true yang bernilai 0 dan nilai kelas sebenarnya true yang bernilai 0.
2. *False Negative* (FN) : Ketika kelas yang diprediksi false yang bernilai 1 dan nilai kelas sebenarnya true yang bernilai 0.
3. *False Positive* (FP) : Ketika kelas yang diprediksi true yang bernilai 0 dan nilai kelas sebenarnya false yang bernilai 1.
4. *True Negative* (TN) : Ketika kelas yang prediksi true yang bernilai 1 dan nilai kelas sebenarnya false yang bernilai 1.

Tabel 8. Confusion Matrik

	Prediksi True	Prediksi False
Actual True	TP	FN
Actual Negative	FP	TN

Accuracy merupakan parameter evaluasi terhadap system menghitung persentase prediksi klasifikasi pada data testing di dibagi dengan total dari *True Positive* (TP), *True Negative* (TN), *False Positive* (FP) dan *False Negative* (FN). Persamaan untuk menghitung Accuracy dituliskan sebagai berikut.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (9)$$

Recall adalah perhitungan rasio persentase prediksi dan terbukti adalah True positif (TP) di dibagi dengan true positif dan false negatif. Persamaan untuk menghitung Recall dituliskan dengan Rumus.

$$Recall = \frac{TP}{TP+FN} \quad (10)$$

Precision perhitungan rasio persentase prediksi dan terbukti adalah *True Positif*(TP) dibagi dengan keseluruhan data prediksi bernilai positif. Persamaan untuk menghitung *Precision* dituliskan sebagai berikut.

$$Precision = \frac{TP}{TP+FP} \quad (11)$$

F1-Score adalah perhitungan untuk mengukur performansi dari gabungan nilai *precision* dan *recall*. Persamaan untuk menghitung *F-Measure* dituliskan sebagai berikut.

$$F1-Measure = 2 \times \frac{Precision \times Recall}{Precision+Recall} \quad (12)$$

4. Evaluasi

Pada bagian ini akan menjelaskan mengenai hasil perbandingan klasifikasi sentiment analisis dengan algoritma *Support Vector Machine* (SVM) dan *Decision Tree*. Terdapat tiga tahap skema untuk menghasilkan hasil yang terbaik, yang pertama mencari rasio data latih dan data uji, kedua mencari term weighting untuk mengetahui performansi yang baik dan terakhir perbandingan algoritma *Support Vector Machine* (SVM) dan *Decision Tree*. Pada tahap terakhir dengan mencari hasil komentar instagram terhadap kinerja PSSI dengan menggunakan hasil pencarian terbaik pada skema sebelumnya.

4.1. Rasio Pembagian Data

Pada tahap ini data yang sudah dikumpulkan dan diberi label akan dipisahkan menjadi data latih dan data uji. Pengujian dilakukan menggunakan 5 komposisi rasio pembagian data, tujuannya untuk mengetahui pada rasio data latih dan data uji berapa model dapat berperformansi dengan baik. komposisi pembagian data latih dan data uji yaitu 90:10, 80:20, 70:30, 60:40 dan 50:50. Penulis melakukan pengujian menggunakan metode pembobotan TF-IDF, TF, TF-RF pada setiap metode klasifikasi *Support Vector Machine* (SVM) dan *Decision Tree*. Ketika hasilnya sudah keluar, maka dihitung rata-rata ketiga metode *term weighting* setiap komposisi rasionya. Berikut hasil yang didapat pada kinerja *Support Vector Machine* (SVM) dan *Decision Tree* pada setiap rasionya.

Tabel 9. Tabel Perbandingan Setiap Rasio Algoritma SVM

Rasio	Akurasi (%)	Precision (%)	Recall (%)	F1-Score (%)
90:10	93.45	95.43	94.37	94.89
80:20	94.00	95.32	95.05	95.18
70:30	93.66	95.54	94.24	94.88
60:40	92.76	95.27	93.23	94.24
50:50	92.34	95.73	92.18	93.92

Tabel 9 menunjukkan rekap hasil dari rata-rata menggunakan tiga term weighting pada klasifikasi *Support Vector Machine* (SVM). Dapat dilihat hasil akurasi terbaik dari *Support Vector Machine* (SVM) dengan komposisi rasio data latih dan data uji pada 80:20 dengan hasil rata-rata akurasi 94.00%, rata-rata precision 95.32%, hasil rata-rata recall 95.05% dan rata-rata F1-Score 95.18%.

Tabel 10. Tabel Perbandingan Setiap Rasio Algoritma Decision Tree

Rasio	Akurasi (%)	Precision (%)	Recall (%)	F1-Score (%)
90:10	84.85	88.19	88.06	88.11
80:20	86.67	88.30	90.08	89.18
70:30	86.63	88.85	89.41	89.12
60:40	84.79	89.28	86.67	87.95
50:50	84.02	88.08	86.35	87.20

Untuk hasil algoritma *Decision Tree* terdapat pada Tabel 10 yang menunjukkan rekap hasil dari rata-rata menggunakan tiga *term weighting* pada klasifikasi *Decision Tree*. Didapatkan akurasi tertinggi agar performansinya lebih baik terdapat dengan komposisi rasio data latih dan data uji pada 80:20 dengan hasil rata-rata akurasi 86.67%, rata-rata precision 88.30%, hasil rata-rata recall 90.08% dan rata-rata F1-Score 89.18%.

Dari hasil yang telah didapatkan pada algoritma SVM komposisi rasio terbaik dengan 80:20 sedangkan pada algoritma *Decision Tree* komposisi rasio terbaik sama dengan algoritma *S Support Vector Machine (SVM)* yaitu 80:20. Maka komposisi rasio 80:20 atau komposisi 2200 data latih dan 550 data uji adalah hasil paling baik dari hasil rata-rata menggunakan tiga term weighting akan dipergunakan pada skema selanjutnya.

4.2. Term Weighting

Pada skema ini penulis melakukan perbandingan pengujian menggunakan metode pembobotan TF-IDF, TF dan TF-RF pada setiap metode klasifikasi *Support Vector Machine (SVM)* dan *Decision Tree*, dengan harapan tiga metode pembobotan ini akan dicoba untuk mengetahui seberapa berpengaruh untuk hasilnya. Karena pada skema sebelumnya mengenai komposisi rasio sudah didapatkan yang terbaik dengan rasio 80:20, maka pada perbandingan metode pembobotan TF-IDF, TF dan TF-RF menggunakan rasio tersebut.

Tabel 11. Tabel Perbandingan Setiap Term Weighting Algoritma SVM

Metode Term Weighting	Akurasi (%)	Precision (%)	Recall (%)	F1-Score (%)
TF-IDF	94.36	96.78	94.30	95.53
TF	94.00	94.44	95.85	95.14
TF-RF	93.64	94.74	95.01	94.88

Tabel 11 menunjukkan rekap hasil dari perbandingan tiga metode pembobotan pada klasifikasi *Support Vector Machine (SVM)*. Dari hasil didapatkan klasifikasi algoritma *Support Vector Machine* dengan menggunakan TF-IDF memiliki akurasi paling tinggi dengan akurasi 94.36%, precision 96.78%, recall 94.30% dan F1-Score 95.53%. Pada hasil SVM dengan pembobotan yang lainpun sudah sangat baik pada SVM dengan TF sebesar 94.00% hanya berselisih 1.53% dari SVM dengan TF-IDF, untuk SVM dengan TF-RF akurasi yang diperoleh sebesar 93.64% hanya berselisih 1.89% dari SVM menggunakan TF-IDF. Maka dari hasil yang didapatkan algoritma *Support Vector Machine (SVM)* menggunakan ketiga term weighting tersebut dapat digunakan dan sudah sangat baik tetapi untuk akurasi yang paling tinggi ketika *Support Vector Machine* menggunakan pembobotan TF-IDF.

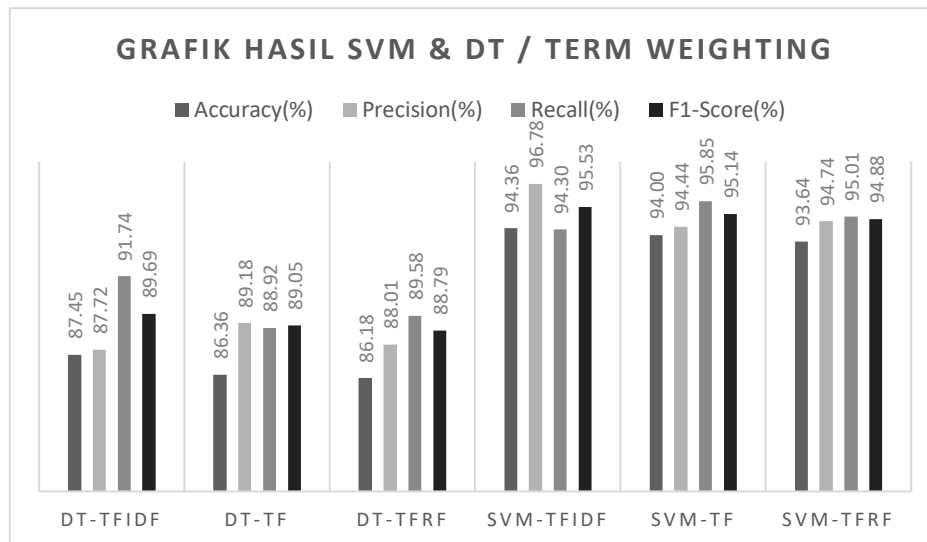
Tabel 12. Tabel Perbandingan Term Weighting Algoritma Decision Tree

Metode Term Weighting	Akurasi (%)	Precision (%)	Recall (%)	F1-Score (%)
TF-IDF	87.45	87.72	91.74	89.69
TF	86.36	89.18	88.92	89.05
TF-RF	86.18	88.01	89.58	88.79

Tabel 12 menunjukkan rekap hasil dari perbandingan tiga metode pembobotan pada klasifikasi *Decision Tree*. Dari hasil didapatkan klasifikasi algoritma *Decision Tree* dengan menggunakan TF-IDF memiliki akurasi paling tinggi dengan akurasi 87.45%, precision 87.72%, recall 91.74% dan F1-Score 89.69%. Pada *Decision Tree* dengan pembobotan yang lain hasilnya yang sangat tidak jauh berbeda, akurasi yang didapat pada *Decision Tree* dengan TF sebesar 86.36% berselisih hanya 1.09% dari *Decision Tree* dengan TF-IDF, untuk *Decision Tree* dengan TF-RF akurasi yang diperoleh sebesar 86.18% berselisih 1.27% dari *Decision Tree* menggunakan TF-IDF. Maka dari hasil yang didapatkan algoritma *Decision Tree* menggunakan pembobotan TF-IDF yang paling baik.

4.3. Comparison Algoritma Support Vector Machine (SVM) dan Decision Tree

Pada skema ini akan dilakukan perbandingan antara algoritma *Support Vector Machine (SVM)* dan *Decision Tree* dengan mempertimbangkan hasil yang didapatkan. Perbandingan ini akan menyimpulkan penggunaan komposisi rasio terbaik, pemilihan metode pembobotan dan melihat hasil setiap algoritma klasifikasi.



Gambar 3. Perbandingan Algoritma Decision Tree dan SVM

Pada gambar 3 menggambarkan bar chart yang membandingkan algoritma *Support Vector Machine* (SVM) dan *Decision Tree* pada setiap *term weighting*. Pada skema sebelumnya telah dilakukan pencarian komposisi rasio data uji dan data latih, dilanjutkan skema yang kedua mencari metode pembobotan yang bisa mengkombinasikan dengan klasifikasi algoritma *Support Vector Machine* (SVM) dan *Decision Tree* dengan hasil terbaik. Pada skema pertama komposisi rasio terbaik data latih dan uji pada 80:20. Pada skema kedua pencarian yang memiliki hasil terbaik untuk setiap algoritma klasifikasi pada penelitian ini, didapatkan algoritma *Support Vector Machine* (SVM) dengan TF-IDF dan *Decision Tree* dengan TF-IDF.

Tabel 13. Tabel Confusion Matrix Hasil Algoritma SVM dengan TF-IDF

Kelas	Prediksi Positif	Prediksi Negatif	Total	Precision	Recall	F1-Score
Aktual Positif	331(96.78%)	11(3.22%)	342	96.78%	94.30%	95.53%
Aktual Negatif	20(9.62%)	188(90.38%)	208			
Akurasi			550	94.36%		

Tabel 14. Tabel Confusion Matrix Hasil Algoritma Decision Tree dengan TF-IDF

Kelas	Prediksi Positif	Prediksi Negatif	Total	Precision	Recall	F1-Score
Aktual Positif	300(87.72%)	42(12.28%)	342	87.72%	91.74%	89.69%
Aktual Negatif	27(12.98%)	181(87.02%)	208			
Akurasi			550	87.45%		


Pada tabel 13 menampilkan *confusion matrix* hasil algoritma SVM dengan TF-IDF, pada kelas positif terlihat bahwa nilai prediksi yang sesuai dengan nilai aktual sebesar 331 komentar atau 96.78% menghasilkan bahwa kelas positif sangat baik dalam mengklasifikasi data tes, pada kondisi kelas negatif terdapat penurunan kualitas klasifikasi yang dimana hanya bisa memprediksi yang benar sebesar 90.38% atau 188 komentar yang true negatif tetapi penurunan ini tidak membuat klasifikasi menjadi jelek karena hasil klasifikasi true negatif masih diatas 90%. Penurunan ini terjadi karena data set yang digunakan tidak seimbang untuk kelas negatif dan positif atau lebih banyak disalah satu kelas. Pada tabel 14 menampilkan *confusion matrix* hasil algoritma *Decision Tree* dengan TF-IDF, pada kelas positif maupun negatif memiliki hasil yang seimbang yang dimana true positif sebesar 87.72% dan true negatif sebesar 87.02% selisihnya tidak begitu jauh, hasil ini menandakan bahwa *decision tree* dengan TF-IDF bisa mengklasifikasi kedua kelas dengan baik dan bisa menangani dataset yang tidak seimbang antara kelas negatif dan positif.

Terlihat pada kedua table bahwa hasil *Support Vector Machine* (SVM) dengan TF-IDF memiliki akurasi 94.36%, precision 96.78%, recall 94.30% dan F1-Score 95.53% sedangkan *Decision Tree* dengan TF-IDF memiliki


akurasi 87.45%, precision 87.72%, recall 91.74% dan F1-Score 89.69%. Maka selisih dari *Support Vector Machine* (SVM) dengan TF-IDF dan *Decision Tree* dengan TF-IDF sangatlah jauh, selisih pada akurasi sebesar 9.33%, pada precision 9.06%, recall 2.56% dan F1-Score 5.84%. Melihat dari hasil *Support Vector Machine* (SVM) dengan TF-IDF lebih baik dibandingkan *Decision Tree* dengan TF-IDF, tetapi hasil dari kedua algoritama tersebut sudah sangat baik dikarenakan memiliki akurasi diatas 80%. Maka pada kasus ini sentiment analisis pada komentar instagram akan lebih baik jika menggunakan *Support Vector Machine* (SVM) dengan TF-IDF karena memiliki hasil paling baik.

4.4. Analisis Sentimen Komentar Instagram Atas Kinerja PSSI

Pada bagian ini merupakan tahapan untuk mencari hasil analisis sentiment komentar pada akun instagram PSSI atas kinerja PSSI. Untuk mencari hal tersebut diperlukan data komentar pada akun instagram PSSI tanpa proses pelabelan. Karena data komentar akan diprediksi oleh sistem terbaik yang sudah dicari pada tahap atau skema sebelumnya yaitu menggunakan *Support Vector Machine* (SVM) dengan TF-IDF. Pengambilan data dilakukan pada bulan november 2019 atau awal mulai terpilihnya ketua umum PSSI yang baru, sampai bulan agustus 2020 untuk pengambilan data dengan 550 komentar per bulan dengan mengambil secara acak tetapi tetapi bersangkutan dengan PSSI. Metode yang digunakan sesuai dengan sistem yang dibangun yang sudah dijelaskan pada bagian dua tetapi tidak melakukan tahapan labelan data. Hasil dari komentar instagram atas kinerja PSSI menggunakan *Support Vector Machine* (SVM) dengan TF-IDF terlihat pada gambar 4 dan 5.



Gambar 4. Hasil Analisis Sentimen Komentar Instagram Mengenai Kinerja PSSI per Bulan



Gambar 5. Hasil Analisis Sentimen Komentar Instagram Mengenai Kinerja PSSI Total 10 Bulan

Berdasarkan gambar 4 menandakan bahwa persatuan sepak bola seluruh Indonesia pada setiap bulannya dominan mendapatkan komentar negatif yang menandakan masyarakat masih kurang puas atas kinerja persatuan sepak bola seluruh Indonesia. Komentar negatif paling tinggi pada bulan agustus 2020 dengan persentase 94.18% yang dimana salah satu berita PSSI yaitu isu naturalisasi pemain di tim nasional Indonesia dan komentar negatif paling rendah pada bulan desember 2019 dengan persentase 56.36% dengan salah satu berita PSSI pada saat itu pencapaian timnas nasional umur dua puluh dua meraih juara dua pada ajang SEA Games 2019. Secara keseluruhan hasil sentimen analisis pada komentar instagram, dengan data sebanyak 5.500 komentar yang diambil mulai bulan November 2019 sampai Agustus 2020 menghasilkan persentase komentar positif 20.13% dan negatif 79.87% .

5. Kesimpulan

Berdasarkan hasil pengujian, komposisi data terbaik untuk melakukan pengujian adalah 80% : 20% (data train : data tes) dengan mendapatkan hasil nilai akurasi 87.45%, precision 87.72%, recall 91.74% dan F1-Score 89.69% pada *Decision Tree* dengan TF-IDF sedangkan untuk *Support Vector Machine* dengan TF-IDF komposisi data terbaik untuk melakukan pengujian adalah 80% : 20% (data train : data tes) dengan mendapatkan hasil nilai akurasi 94.36%, precision 96.78%, recall 94.30% dan F1-Score 95.53%. Melihat dari hasil *Support Vector Machine* (SVM) dengan TF-IDF lebih baik dibandingkan *Decision Tree* dengan TF-IDF, tetapi hasil dari kedua algoritama tersebut sudah sangat baik dikarenakan memiliki akurasi diatas 80%. Maka pada kasus ini sentiment analisis pada komentar instagram akan lebih baik jika menggunakan *Support Vector Machine* (SVM) dengan TF-IDF karena memiliki hasil paling baik.

Merujuk dari hasil analisis sentimen komentar masyarakat pada Instagram mengenai kinerja persatuan sepak bola seluruh Indonesia (PSSI) yang mengambil data pada bulan november 2019 sampai agustus 2020, bahwa masyarakat masih kurang puas akan kinerja PSSI. Dengan persentase sebesar 79.87% komentar negatif atau tidak puas dan 20.13% komentar positif atau puas atas kinerjanya sepak bola seluruh Indonesia (PSSI).

Saran untuk penelitian selanjutnya disarankan mencari cara untuk mendeteksi komentar instagram yang mengandung isi jual produk dan spam, agar memudahkan pada pemilihan data dan preprocessing. Saran selanjutnya mengenai penggunaan data yang seimbang untuk setiap kelas.

Daftar Pustaka

- [1] Arifianto, N. (2017, Desember 19). *Indonesia Negara Penggila Sepak Bola Nomor Dua di Dunia*. Retrieved from CNN Indonesia: <https://www.cnnindonesia.com/olahraga/20171219204103-142-263606/indonesia-negara-penggila-sepak-bola-nomor-dua-di-dunia>
- [2] Setiyoko, A. (2019, January 16). *Satgas Antimafia Bola Terima 338 Laporan Dugaan Pengaturan Skor, Termasuk Soal Ancaman*. Retrieved from Bola Sport: <https://www.bolasport.com/read/311607559/satgas-antimafia-bola-terima-338-laporan-dugaan-pengaturan-skor-termasuk-soal-ancaman>
- [3] *Instagram users in Indonesia*. (2020, Juli). Retrieved from NapoleonCat: <https://napoleontcat.com/stats/instagram-users-in-indonesia/2020/07>
- [4] Liu, B. (2012). *Sentiment Analysis and Opinion Mining*. Morgan & Claypool Publishers.
- [5] Pang, B., Lee, L., & Vithyanathan, S. (2002). Thumbs Up ? Sentiment Classification Using Machine Learning Techniques. *Proceedings of The ACL-02 conference*, 79-86.
- [6] Widyaningtyas, W. C., Adiwijaya, & Faraby, S. A. (2018). Klasifikasi Sentiment Analysis pada Review Film Berbahasa Inggris dengan Menggunakan Metode Doc2Vec dan Support Vector Machine (SVM). *e-Proceeding of Engineering ., Vol.5, No.1*, 1570-1578.
- [7] Susanti, N. D., Sudiyono, E., & Sembiring, I. (2018). Uji Perbandingan Akurasi Analisis Sentimen Pariwisata Menggunakan Algoritma Support Vector Machine dan Naive Bayes. *Nusantara of Engineering*, 3(2), 26-33.
- [8] Suyanto. (2017). *Data Mining Untuk Klasifikasi dan Klatering Data*. Bandung: Penerbit Informatika. Tambunan, M. G., & Setiawan, E. B. (n.d.). Prediksi Kepribadian DISC Pada Twitter Menggunakan Metode Decision Tree C4.5.
- [9] Feldman, Ronen, and James Sanger, *The Text Mining Handbook Advanced Approaches in Analyzing Unstructured Data*. Cambridge; New York: Cambridge University Press, 2007.
- [10] S. W. S. A. D. Fasihol Nurhuda, "Analisis Sentimen Masyarakat Terhadap Calon Presiden Indonesia 2014 Berdasarkan Opini dari Twitter Menggunakan Metode Naive Bayes Classifier," *Jurnal ITSMART*, vol. II, no. 2, 2013.
- [11] Mujilawati, S. (2016). Pre-Processing Text Mining Pada Data Twitter. *Semin. Nas. Teknol. Inf. Dan Komun., vol. 2016, no. Sentika*.
- [12] Angiani, G., & ddk. (2016). A comparison between preprocessing techniques for sentiment analysis in Twitter. *CEUR Workshop Proc., vol. 1748, no. MI*.
- [13] Rahmadini, A. (2014). Aplikasi Penelusuran Opini Publik Terhadap Telkom University Menggunakan Pembobotan TF-IDF.
- [14] Akbar, M. T. (2012). Analisis Perbandingan Metode Pembobotan Kata TF.IDF dan TF.RF Terhadap Performansi Kategorisasi Teks
- [15] Tambunan, M. G., & Setiawan, E. B. (n.d.). Prediksi Kepribadian DISC Pada Twitter Menggunakan Metode Decision Tree C4.5.
- [16] Putri, N. E. (2014). Analisis Perbandingan Metode Pembobotan TF.CHI2 dan TF.RF Terhadap Kategorisasi Teks Berbahasa Indonesia.