

Analisis Sentimen Kepuasan Pelanggan Terhadap Internet Provider Indihome di Twitter Menggunakan Metode Decision Tree dan Pembobotan TF-IDF

Shakina Rizkia¹, Erwin Budi Setiawan S.Si., M.T², Diyas Puspendari S.S., M.Pd³

^{1,2,3}Fakultas Informatika, Universitas Telkom, Bandung

¹shakinarizkia@students.telkomuniversity.ac.id , ²erwinbudisetiawan@telkomuniversity.ac.id ,
³diyaspuspendari@telkomuniversity.ac.id ,

Abstrak

Kepuasan pelanggan merupakan salah satu faktor untuk mengukur kesuksesan sebuah layanan pada suatu perusahaan jasa. Kepuasan pelanggan umumnya digunakan oleh perusahaan jasa sebagai bahan evaluasi untuk memperbaiki layanan yang diberikan. Salah satu cara untuk mengukur kepuasan pelanggan adalah dengan menggunakan analisis sentimen untuk mengklasifikasikan opini pelanggan terhadap layanan tersebut ke dalam kelas positif, negatif dan netral, sehingga diperoleh seberapa besar pelanggan yang puas terhadap layanan yang diberikan berdasarkan banyaknya opini positif, negatif, maupun netral. Data diperoleh dari tweet tentang opini pelanggan terhadap layanan indihome. Metode yang digunakan dalam tugas akhir ini adalah *Decision Tree* dengan menggunakan pembobotan Term Frequency-Inverse Document Frequency (TF-IDF). Berdasarkan hasil eksperimen, didapatkan akurasi maksimal sebesar 80,1 % dengan menggunakan bigram dan pembobotan TF-IDF.

Kata kunci : Analisis Sentimen, *Decision Tree*.

Abstract

Customer satisfaction is one factor to measure the success of a service in a service company. Customer satisfaction is generally used by service companies as an evaluation material to improve the services provided. One way to measure customer satisfaction is to use sentiment analysis to classify customer opinions on these services into a positive, negative and neutral class, so that the amount of customers who are satisfied with the service provided is based on the number of positive, negative, and neutral opinions. Data is obtained from tweets about customer opinions on indihome services. The method used in this final project is the Decision Tree using weighting Term Frequency-Inverse Document Frequency (TF-IDF). Based on the experimental results, obtained a maximum accuracy of 80,1% by using bigram and weighting TF-IDF.

Keywords: Sentiment Analysis, *Decision Tree*

1. Pendahuluan

Pada perkembangan teknologi saat ini, internet telah menjadi salah satu media yang sering digunakan untuk mencari atau mendapatkan informasi dari seluruh dunia. Pada tahun 2018 pengguna Internet di Indonesia telah mencapai 171,17 juta jiwa dimana angka ini mengalami kenaikan 10,12% dibandingkan tahun sebelumnya yang hanya mencapai 143,26 juta jiwa, menurut data yang dikeluarkan oleh APJII [2]. Salah satu perusahaan penyedia layanan internet di Indonesia adalah Indihome, yang pada saat ini telah memiliki banyak pelanggan. Dengan besarnya jumlah pengguna dari layanan Indihome ini, maka akan dapat melahirkan berbagai opini, baik opini bersifat pujian maupun keluhan.

Twitter adalah sebuah media sosial dengan fitur micro-blogging yang memiliki jumlah pengguna dan database yang besar dan terus berkembang hingga saat ini [1][4]. Di Indonesia tercatat pengguna aktif Twitter pada tahun 2016 mencapai 24,3 juta orang. Twitter seringkali dijadikan tempat untuk menyampaikan opini terhadap tokoh publik, layanan publik maupun produk dari sebuah perusahaan, tidak terkecuali dengan produk Indihome, banyak pengguna layanan Indihome yang menyampaikan opini mereka terhadap produk ini baik berupa opini positif, negatif, maupun netral.

Dengan beragamnya opini yang muncul tersebut, apabila diteliti lebih lanjut maka akan dihasilkan sebuah sentimen yang dapat berguna untuk mengetahui tingkat kepuasan pelanggan terhadap sebuah produk atau layanan tersebut, sehingga dapat menjadi bahan evaluasi terhadap layanan Indihome agar dapat meningkatkan kualitas pelayanannya. Analisis sentimen adalah studi yang bertujuan untuk menganalisis opini, sentimen dan emosi yang terdapat pada dokumen atau data [4]. Tugas dasar dari analisis sentimen adalah untuk mengelompokkan sifat dari teks yang ada di dalam kalimat maupun pendapat, yang pada umumnya terbagi menjadi 3 kelas yaitu negatif, positif dan netral [3]. Metode yang digunakan untuk menganalisis opini terhadap layanan Indihome adalah *Decision Tree*, metode tersebut dipilih karena memiliki nilai akurasi yang lebih baik.

Berdasarkan latar belakang yang sudah diuraikan di atas, maka dapat diambil beberapa masalah yang dapat dibahas dalam tugas akhir ini yaitu seberapa besar tingkat kepuasan pelanggan Indihome di media sosial Twitter, dan berapa besar tingkat akurasi yang didapatkan oleh metode *Decision Tree*. Adapun masalah yang

menjadi batasan pekerjaan dalam tugas akhir ini adalah pelabelan tweet dilakukan secara manual karena sampai saat ini belum ada pelabelan secara otomatis dan pada proses *filtering* dilakukan secara manual karena belum ada aplikasi yang bisa memfilter sebuah dokumen yang termasuk dalam opini atau tidak secara otomatis.

Tujuan dari tugas akhir ini yaitu untuk mengetahui seberapa besar tingkat kepuasan pelanggan Indihome di media sosial Twitter, dan untuk mengetahui akurasi yang dihasilkan oleh metode *Decision Tree* yang diimplementasikan pada analisis sentimen.

2. Studi Terkait

Berikut merupakan studi yang berkaitan dengan topik tugas akhir ini

2.1 Decision Tree

Decision Tree adalah representasi sederhana untuk mengklasifikasikan suatu contoh. Proses dalam decision tree yaitu mengubah bentuk data (tabel) menjadi model pohon (tree) kemudian mengubah model pohon tersebut menjadi aturan (rule). Algoritma yang digunakan adalah algoritma ID3. Algoritma ID3 menggunakan konsep dari *Entropy* dan *Information Gain*. Untuk nilai *Entropy* dapat ditemukan dengan menggunakan rumus:

$$Entropy(S) = \sum_{j=1}^k -p_j \log_2 p_j$$

Keterangan:

S adalah ruang (data) *sample* yang digunakan untuk *training*

K adalah banyaknya partisi pada S

p_j adalah probabilitas yang didapat dari $\text{Sum}(Y_a)$ dibagi dengan total *sample*

Untuk nilai *Information Gain* (IG) dapat ditemukan dengan menggunakan rumus berikut ini:

$$Gain(A) = Entropy(S) - \sum_{i=1}^k \frac{|S_i|}{|S|} \times Entropy(S_i)$$

Keterangan:

S adalah ruang (data) *sample* yang digunakan untuk *training*

A adalah atribut

$|S_i|$ adalah jumlah *sample* untuk nilai V

$|S|$ adalah jumlah seluruh *sample* data

$Entropy(S_i)$ adalah *entropy* untuk *sample – sample* yang memiliki nilai i

2.2 Term Frequency – Inverse Document Frequency (TF-IDF)

Term Frequency – Inverse Document Frequency (TF-IDF) merupakan sebuah algoritma untuk menunjukkan frekuensi kata yang keluar dalam dokumen. *Term Frequency* (TF) adalah frekuensi munculnya kata dalam suatu dokumen, sedangkan *Document Frequency* (DF) adalah banyaknya dokumen yang mengandung kata tertentu. Nilai bobot didapat dari TF dan *Inverse* dari DF [5]

$$IDF(w) = \log\left(\frac{N}{DF(w)}\right)$$

$$TF - IDF(w, d) = TF(w, d) \times IDF(w)$$

Keterangan:

TF-IDF (w,d) : bobot kata dalam sebuah dokumen

W (*word*) : suatu kata

D (*Document*) : dokumen

TF(w,d) : frekuensi kemunculan kata w dalam d

IDF(*Inverse Document Frequency*)(w) : inverse DF dari w

N : banyaknya dokumen

DF(w) : banyaknya kata dalam dokumen

2.3 Confusion Matrix

Confusion Matrix merupakan sebuah metode untuk mengukur performansi pada *supervised learning* [6]. Metode ini memiliki 4 keluaran yaitu

a. Recall

Recall adalah perhitungan yang berguna untuk mengetahui seberapa besar presentase kasus true yang diidentifikasi true. Persamaan untuk menghitung *recall* adalah :

$$Recall = \frac{d}{c + d}$$

b. Precision

Precision adalah perbandingan antara kasus true yang diidentifikasi true dengan semua hasil prediksi bernilai positif. Persamaan untuk menghitung precision adalah :

$$Precision = \frac{d}{b + d}$$

c. Accuracy

Accuracy adalah perbandingan antara semua hasil prediksi negatif dengan seluruh data. Persamaan untuk menghitung Accuracy adalah :

$$Accuracy = \frac{a + c}{a + b + c + d}$$

d. Error Rate

Error Rate adalah perbandingan antara salah satu hasil prediksi dengan seluruh data. Persamaan untuk menghitung Error rate adalah :

$$Error\ rate = \frac{b + c}{a + b + c + d}$$

Keterangan

A = hasil prediksi negatif dan data sebenarnya negatif.

B = hasil prediksi positif dan data sebenarnya negatif.

C = hasil prediksi negatif dan data sebenarnya positif.

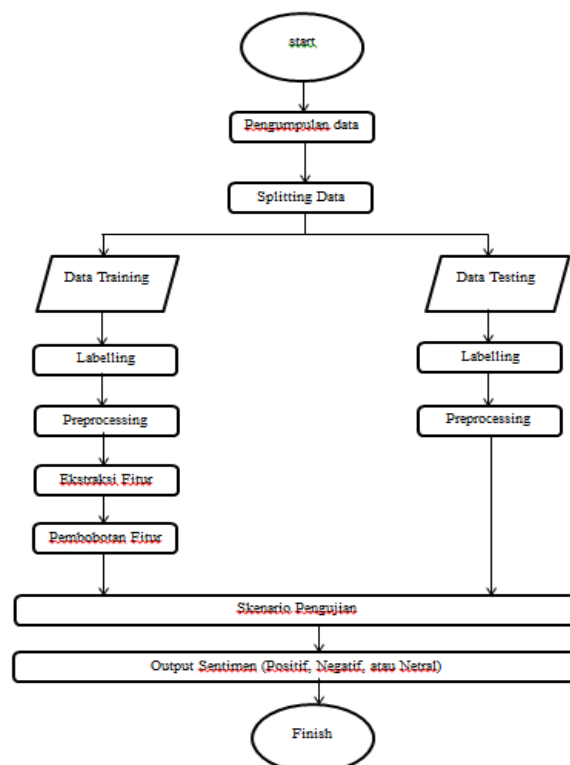
D = hasil prediksi positif dan data sebenarnya positif.

2.4 N-Gram

N-Gram adalah proses pemecahan kalimat menjadi kata-kata berdasarkan n kata yang dipilih. Berdasarkan [7] N-Gram dibagi menjadi tiga jenis yaitu Unigram untuk pemecahan kalimat menjadi token yang berisi satu kata, Bigram untuk pemecahan kalimat menjadi token yang berisi dua kata dan trigram untuk pemecahan kalimat menjadi token yang berisi tiga kata.

3. Sistem yang dibangun

Secara umum sistem yang akan dibuat dalam tugas akhir ini adalah sebagai berikut:



3.1 Pengumpulan Data

Pengambilan data dari Twitter dilakukan menggunakan aplikasi *automatic crawling twitter* [8] melalui API Twitter dengan mengambil seluruh cuitan yang mengandung kata “indihome” pada Twitter.

Tabel 1. Contoh cuitan beserta labelnya

No	Cuitan	Label
1	@TelkomCare hujan sebentar aja sinyal nya down gini indihome	Negatif
2	Indihome jaringan terutama di daerah Pandeglang sedang busuk-busuknya, jgn coba-coba main Mobile Legend pake wifi Indihome. -> @TelkomCare	Negatif
3	@TelkomCare min losnya sdh hilang dan indihome sy udh kembali normal. Trims	Positif
4	Akhir nya indihome channel useeTV nya dibuka semua, kira kira sampai kapan yes ? @IndihomeFiber	Positif
5	untuk biaya langganan indihome 1P yg internet berapa ya ? Dan biaya total termasuk pemasangan berapa ?	Netral
6	Kak , untuk paket IndiHome saat ini bisa dicek di website kami . Trims -Arin	Netral

3.2 Preprocessing

Data yang diperoleh dari tahap sebelumnya dilakukan pemrosesan untuk mengubahnya menjadi data yang siap diolah. Tahap *preprocessing* ini memiliki beberapa tahapan diantaranya, yaitu:

- Case folding* : mengubah seluruh huruf menjadi huruf kecil
- Cleansing* : membersihkan dokumen dari karakter – karakter special yang tidak terbaca sistem
- Normalisasi : mengubah kata singkatan dan kata tidak baku menjadi kata baku
- Stemming* : menghilangkan imbuhan pada kata
- Stopwords* : menghilangkan kata – kata yang tidak penting seperti kata sambung dan kata ganti orang

3.3 Ekstraksi Fitur

Data training kemudian masuk ke dalam tahap ekstraksi fitur, pada tahap ini akan diambil fitur – fitur yang akan menjadi atribut penilaian metode yang digunakan. Ada 2 fitur utama yang diambil dari data training yaitu :

Tabel 2. Fitur yang didapat

No	Fitur	Rincian
1	Tokenisasi	Unigram, Bigram, Trigram

3.4 Pembobotan fitur

Fitur token kata yang telah diambil dari data training akan dilakukan pembobotan, ada 2 macam pembobotan kata pada fitur kata ini yaitu:

- Pembobotan dengan menggunakan algoritma *Term Frequency-Inverse Document Frequency* (TF-IDF) dengan berdasarkan frekuensi kata tersebut muncul pada suatu cuitan dan frekuensi kata tersebut muncul pada satu dokumen.

b. Pembobotan kata berdasarkan muncul tidaknya kata tersebut dalam satu dokumen, apabila kata tersebut muncul dalam dokumen, maka kata tersebut bernilai 1 (ada) dan bernilai 0 (tidak ada) jika tidak muncul dalam dokumen.

Sedangkan untuk fitur *tweet-based* pembobotan dilakukan berdasarkan banyaknya fitur tersebut muncul dalam data training

3.5 Skenario Pengujian

Proses skenario pengujian ini dilakukan dengan menggunakan 2 fitur utama yang berisi fitur dasar, dan fitur *Term Frequency-Inverse Document Frequency* (TF-IDF).

Tabel 3. Skenario Percobaan

Fitur	Jumlah Skenario	Skenario	
A. Fitur dasar	3 skenario	A.1	Unigram
		A.2	Bigram
		A.3	Trigram

4. Hasil dan Analisis

Pada bab ini skenario yang telah dibuat akan diuji menggunakan data latihan yang didapatkan dari tahap *splitting data*

4.1 Dataset dan Labelling

Data yang digunakan pada penelitian ini sebanyak 1934 data yang berasal dari hasil *crawling twitter* yang kemudian dibagi menjadi dua berdasarkan skenario pemecahan data terbaik yaitu dengan rasio 70% data training dan 30% data testing. Data tersebut dilabelkan secara manual ke dalam 3 kelas yaitu positif negatif dan netral. Pada data training mengandung 113 kelas positif 808 kelas negatif dan 432 kelas netral, sedangkan pada data testing mengandung 15 kelas positif 379 kelas negatif dan 186 kelas netral.

4.2 Hasil Pengujian

Berikut merupakan hasil pengujian dan hasil klasifikasi dari sistem yang dibuat:

4.2.1 Pengukuran Performansi

Pengukuran dilakukan dengan metode *confussion matrix* dengan membandingkan hasil label dari sistem dengan hasil label dari pelabelan manual sehingga didapatkan akurasi terbaik dari skenario yang dijalankan.

Tabel 4. Hasil pengujian klasifikasi menggunakan Decision Tree

Fitur	Skenario	Jumlah Feature	Akurasi (%)
Fitur dasar	A.1	1542	78,9 %
	A.2	3909	80,1 %
	A.3	6678	77,9 %

Berikut ini merupakan tabel *confussion matrix* berdasarkan skenario terbaik dari tabel 4 hasil pengujian klasifikasi menggunakan metode *decision tree*

Tabel 5. Hasil *Confussion Matrix*

	Positif	Negatif	Netral
Positif	53	31	29
Negatif	3	688	117
Netral	12	77	343

Dari hasil pengujian pada tabel didapatkan skenario dengan akurasi terbaik yaitu skenario A.2 (Bigram dengan pembobotan TF-IDF) dengan akurasi 80,1%.

4.3 Analisis Hasil Pengujian

Berdasarkan hasil dari pengujian yang telah dilakukan menunjukkan bahwa pada pengujian didapatkan hasil akurasi terbaik sebesar 80,1% pada skenario bigram dengan pembobotan TF-IDF. Berdasarkan tabel 5 dapat dilihat bahwa sentimen negatif yang diterima oleh Indihome lebih banyak dibandingkan dengan sentimen positif ini membuktikan bahwa kepuasan pelanggan terhadap produk Indihome masih rendah, sedangkan untuk sentimen netral tidak terlalu mempengaruhi kepuasan pelanggan, karena sebagian besar sentimen netral berisi pertanyaan dan promosi produk Indihome. Berikut Pohon Keputusan terbaik (Bigram) untuk penelitian ini bisa dilihat di lampiran.

5. Kesimpulan

Berdasarkan hasil dari eksperimen dapat disimpulkan bahwa tingkat kepuasan pelanggan Indihome cukup rendah terlihat dari data yang diujikan, hampir 30% merupakan opini negatif dan hasil implementasi decision tree mendapatkan akurasi sebesar 80,1%. Dengan akurasi 80,1% belum terbilang memuaskan, disebabkan oleh jumlah data yang kurang besar dan fitur yang masih sedikit sehingga belum cukup tepat untuk mengklasifikasikan sebuah opini.

Daftar Pustaka

- [1]Agarwal, A. e. (2011). Sentiment Analysis of twitter data. *Proceedings of the workshop on language in sosial media*.
- [2]Nabila, M. (2019, Mei 16). *Survei APJII : Pengguna Internet di Indonesia Capai 171,17 Juta Sepanjang 2018* Retrieved from DailySocial.id: <https://dailysocial.id/post/pengguna-internet-indonesia-2018>
- [3]Avanco, L. V., & Nunes, M. G. (2014). Lexicon-based Sentiment Analysis for Reviews of Products in Bazillian Portuguese. *Brazillian Conference on Intelligent System*, 277-281.
- [4]Medhat, Walaa, Hasan, A., & Korashy, H. (2014). Sentiment Analysis algorithm and applications : A survey . *Ains Shans Engineering Journal*, 1093-1113.
- [5]Feldman, R., & Sanger, J. (2007). *The Text Mining Handbook*. New York: Cambridge University Press.
- [6]Lina L. Dhande, D. P. (2014). Analyzing Sentiment of Movie Review Data. *International Journal of Emerging Trends & Technology in Computer Science*, 316-320.
- [7]Daniel Jurafsky, James H. Martin. 2000. *Speech and Language Processing*. New Jersey: Prentice Hall PTR Upper Saddle River.
- [8]Sembodo, J. E., Setiawan, E. B., & Baizal, Z. A. (2016). Data Crawling Otomatis pada Twitter. *Ind. Symposium on Computing*, 11-16.

hilang > 0: negatif (2.0)
 internet > 0: negatif (2.0)
 mohon > 0
 indihome nomor <= 0
 indigo <= 0
 info <= 0: negatif (13.0)
 info > 0: netral (3.0/1.0)
 indigo > 0: netral (2.0)
 indihome nomor > 0: netral (2.0)
 bagaimana > 0
 bagaimana indihome <= 0: netral (29.0/3.0)
 bagaimana indihome > 0: positif (2.0/1.0)
 terima kasih > 0
 indihome sialan <= 0
 halo <= 0
 kali <= 0
 langgan <= 0
 selamat siang <= 0
 aju <= 0
 internet <= 0
 aktif <= 0
 aplikasi myindihome <= 0
 indihome proses <= 0
 ya terima <= 0: positif (25.0/5.0)
 ya terima > 0: netral (3.0/1.0)
 indihome proses > 0: netral (2.0)
 aplikasi myindihome > 0: netral (2.0)
 aktif > 0: netral (2.0)
 internet > 0: netral (5.0)
 aju > 0: netral (3.0/1.0)
 selamat siang > 0: negatif (2.0/1.0)
 langgan > 0: negatif (2.0/1.0)
 kali > 0: negatif (2.0/1.0)
 halo > 0: negatif (4.0/1.0)
 indihome sialan > 0: negatif (2.0)
 tidak > 0
 netflix <= 0
 tidak indihome <= 0
 minggu <= 0
 layan <= 1.886361
 halo <= 0
 terima <= 0
 indihome ya <= 0
 coba <= 0
 tidak pakai <= 0
 jurdilorg tidak <= 0
 internet <= 0
 televisi <= 0
 pakai <= 0
 langgan <= 0
 aktif <= 0
 bantu <= 0
 salah <= 0: negatif (106.0/24.0)

| | | | | pasang > 0: netral (2.0)
| | | | ganggu > 0: negatif (79.0/4.0)
| | | lot > 0: negatif (28.0)
| | lampu > 0: negatif (35.0)
| eror > 0: negatif (34.0)
anak indihome > 0: netral (63.0/13.0)

Number of Leaves : 108

Size of the tree : 215