

Analisis Sentimen Mengenai Pasca Bencana Alam Menggunakan Metode *K-Nearest Neighbor (K-NN)* dan *Decision Tree*

Vira Arum Shahputri¹, Yuni Yamasari²

^{1,2} Jurusan Teknik Informatika/Teknik Informatika, Universitas Negeri Surabaya

¹vira.17051204002@mhs.unesa.ac.id

²yuniyamasari@unesa.ac.id

Abstrak— Indonesia sering mengalami bencana alam seperti *angin puting beliung, banjir, gempa bumi, letusan gunung berapi, tanah longsor, dan tsunami*. Bencana alam kerap diberitakan di media sosial. Salah satu platform media sosial paling cepat menyebarkan informasi adalah *twitter*. *Twitter* memungkinkan orang untuk secara bebas mengutarakan pendapat dan pandangannya tentang peristiwa terkini atau masa lalu. Tujuan dari penelitian ini adalah menggunakan analisis sentimen untuk mengetahui kategori sentimen mana yang dihasilkan berdasarkan informasi pasca bencana alam. Bagaimana cara masyarakat menyampaikan pendapat, termasuk sikap empati, dengan mengutarakan pendapat positif atau negatif di media sosial. Tujuan selanjutnya adalah mengetahui perbandingan keakuratan metode *K-NN* dan *Decision Tree* dengan fitur tambahan seperti *TF-IDF*, *N-Gram*, dan gabungan *TF-IDF N-Gram*. Proses pengumpulan data dilakukan dengan menggunakan teknik *crawling* dengan jumlah data yang digunakan sebanyak 2400 data. Untuk proses pelabelan setelah proses *preprocessing* menggunakan proses labelling *TextBlob* dan *VADER*. Hasil penelitian ini menunjukkan bahwa kelas sentimen yang dihasilkan dari tahapan labelling *TextBlob* dan *VADER* merupakan kelas sentimen negatif. Data labelling *TextBlob* memberikan nilai akurasi yang lebih baik dibandingkan labelling *VADER*. Sedangkan untuk hasil pengujian, metode *K-NN* dengan fitur *unigram* memiliki nilai *accuracy* tinggi sebesar 78,95%, *precision* 72%, *recall* 38,30%, dan *f-1 score* 50%. Sedangkan metode *Decision Tree* memiliki nilai akurasi yang lebih baik dibandingkan metode *K-NN* dengan tambahan fitur *TF-IDF* & gabungan *TF-IDF Unigram* yaitu sebesar 81,29%, *precision* 94,12%, *recall* 34,04%, dan *f-1 score* 50%.

Kata Kunci— Analisis Sentimen, N-Gram, TF-IDF, K-NN, Decision Tree.

I. PENDAHULUAN

Memasuki awal tahun 2021 beberapa wilayah di Indonesia mengalami bencana alam. Bencana alam mengacu pada fenomena alam seperti *banjir, gempa bumi, angin puting beliung, tanah longsor, dan tsunami*. Berdasarkan data Badan Nasional Penanggulangan Bencana (BNPB), Indonesia mengalami 1.441 kali kasus bencana sejak awal Januari hingga 18 Juni 2021. Bencana tersebut antara lain *banjir* (599 kasus), *puting beliung* (398 kasus), *tanah longsor* (293 kasus), *gempa bumi* (20 kasus), dan *kebakaran hutan dan lahan* (109 kasus) [1].

Di era yang sudah semakin canggih dan berkembang, masyarakat Indonesia semakin banyak yang menggunakan perangkat elektronik. Perangkat elektronik seperti *hp, laptop, dan notebook* tidak hanya digunakan untuk berkomunikasi, tetapi juga digunakan untuk memperoleh informasi mengenai keadaan sekitar. Masyarakat bisa mendapatkan informasi dari berbagai media sosial. Sejauh ini, media sosial menjadi salah satu sarana dalam peyebaran informasi tercepat. *Twitter* merupakan salah satu media sosial terpopuler yang menyebarkan informasi paling cepat. Media sosial *twitter* merupakan salah satu media sosial yang paling banyak digunakan. Berdasarkan informasi mengenai pasca bencana alam di beberapa wilayah Indonesia, terdapat *tweet* opini masyarakat mengenai informasi tersebut. Karena banyaknya *tweet* yang dapat diproses secara manual, maka digunakan teknik yang disebut *text mining* untuk mengolah data teks. Teknik *text mining* digunakan untuk menemukan informasi yang bisa diambil dari kumpulan data yang sangat besar. Penelitian ini menganalisis *tweet* opini masyarakat mengenai informasi pasca bencana alam yang terjadi di Indonesia.

Analisis sentimen adalah sebuah proses memahami dan mengungkapkan pendapat, evaluasi, penilaian sikap, atau pandangan seseorang terhadap sebuah teks dan memperoleh informasi secara otomatis dengan mengolah data tekstual [2]. Analisis sentimen dilakukan untuk menentukan opini terhadap suatu permasalahan, apakah termasuk dalam kelas opini positif, negatif, atau netral.

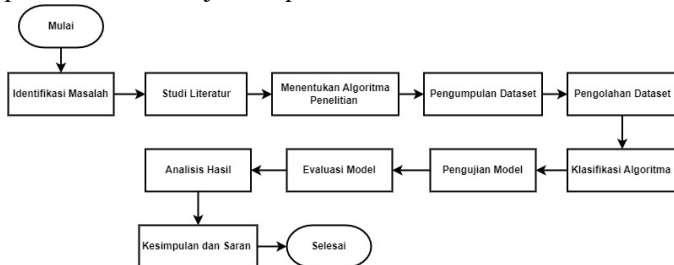
Terdapat beberapa penelitian sebelumnya mengenai analisis sentimen. Penelitian oleh Nova Tri Romadhoni dkk [3] membandingkan metode *Naive Bayes*, *K-NN* dan *Decision Tree* untuk menganalisis sentimen pada transportasi *KRL Commuter Line*. Hasil akurasi dengan *Naive Bayes* 80%, akurasi dengan *K-NN* 80%, dan akurasi dengan *Decision Tree* 100%. Penelitian yang dilakukan oleh Achmad Bayhaqi dkk [4] melakukan penelitian analisis sentimen E- Commerce berdasarkan *tweet* menggunakan *Decision Tree*, *K-Nearest Neighbor (K-NN)* dan *Naive bayes*. Fitur yang digunakan adalah *TF-IDF* dengan akurasi metode *Decision Tree* sebesar 80%, metode *K- Nearest Neighbor (K-NN)* akurasi sebesar 78%. Sedangkan menggunakan metode *Naive Bayes* akurasi sebesar 77%. Rani Puspita dan Agus Widodo[5] melakukan penelitian lebih lanjut yang membandingkan metode *K-NN*, *Decision Tree* dan *Naive Bayes* terhadap sentimen pengguna layanan BPJS. Akurasi dari metode *K-NN* sebesar 96.01%,

metode *Decision Tree* akurasi mencapai 96.13%, Dengan metode *Naive Bayes* akurasi 89.14%. Penelitian oleh Muhammad Syarifuddin [6] tentang analisis sentimen opini publik mengenai dampak *PSBB* di *Twitter* menggunakan Algoritma *Decision Tree*, *K-NN*, *Naive Bayes*. Penelitian ini memanfaatkan penambahan fitur *TF-IDF*. Hasil akurasi *Decision Tree* yaitu 83.3%, *K-NN* 80.80%, dan *Naive Bayes* sebesar 80.03%. Pada tahun 2020, Ainun Zumarniansyah dkk [7] melakukan penelitian tentang *Twitter* Sentiment Analysis Of Post Natural Diasters Using Comparative Classification Algorithm *Support Vector Machine* And *Naive Bayes*. Penelitian ini menggunakan fitur *TF-IDF*, akurasi *SVM* sebesar 51.18%, sedangkan akurasi *Naive Bayes* sebesar 48.11%.

Beberapa penelitian terdahulu, menunjukkan bahwa metode *K-Nearest Neighbor (K-NN)* dan *Decision Tree* juga memiliki nilai akurasi yang cukup tinggi jika dibandingkan dengan metode lainnya. Penelitian ini dibuat untuk mengetahui dari informasi setelah terjadinya bencana alam, masyarakat menyampaikan opini yang dituangkan dalam media sosial sudahkah termasuk pada sikap berempati dengan menuangkan opini yang positif atau menuangkan dalam opini yang negatif. Selanjutnya, tujuan dari penelitian ini adalah untuk membandingkan hasil akurasi dari metode yang digunakan dengan penambahan *N-gram*, fitur *TF-IDF* serta gabungan dari *TF-IDF N-Gram*.

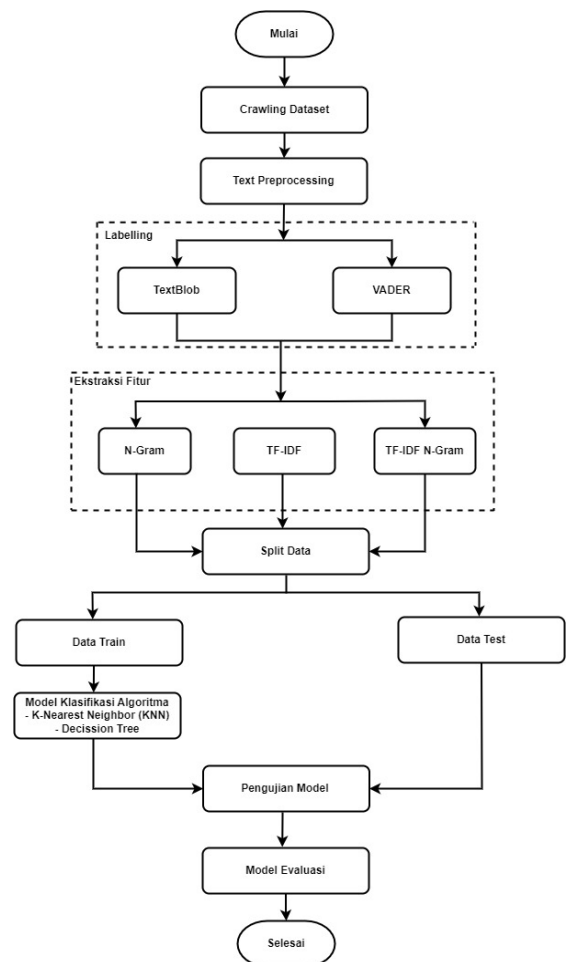
II. METODOLOGI PENELITIAN

Penelitian memerlukan suatu proses yang sering disebut dengan metodologi penelitian. Untuk mencapai tujuan penelitian, diterapkan petunjuk penggunaan metodologi penelitian atau bahan referensi. Diagram alir penelitian dari penelitian ini ditunjukkan pada Gbr. 1.



Gbr. 1 Diagram Alur Penelitian

Tujuan dari penelitian ini adalah untuk menentukan kelas sentimen yang dihasilkan dari data informasi pasca bencana alam dan untuk membandingkan metode *K-NN* dan *Decision Tree* yang digunakan dengan menggunakan tambahan fitur *N-Gram*, *TF-IDF*, dan gabungan dari *TF-IDF N-Gram*. Diagram alur sistem penelitian analisis sentiment ditunjukkan dalam Gbr. 2.

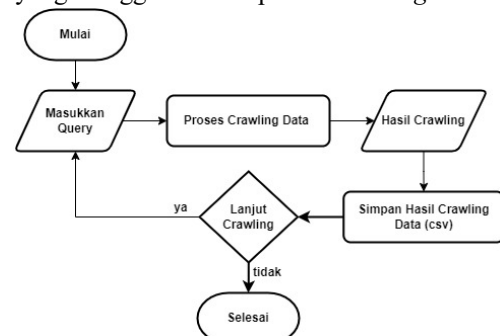


Gbr. 2 Alur Sistem Penelitian

A. Crawling Dataset

Crawling dataset *tweet* yaitu pengambilan data yang dilakukan pada media sosial *twitter*. Proses *crawling tweet* menggunakan *Jupyter Notebook*.

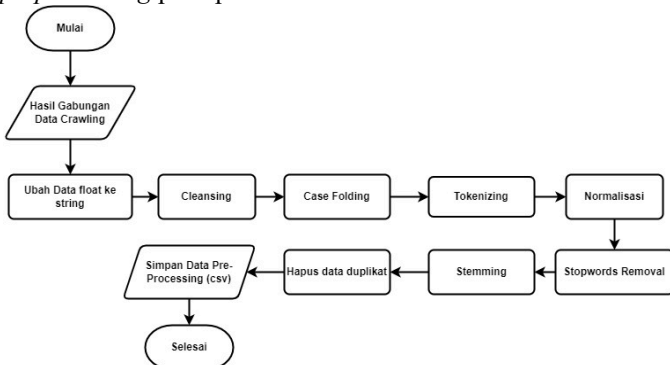
Proses *crawling* data *tweet* dilakukan dengan pencarian berdasarkan *query* pada beberapa kategori yaitu *angin puting beliung*, *banjir*, *gempa*, *tsunami* atau *gelombang pasang*, *tanah longsor*, dan *gunung meletus*. Setelah memperoleh data, kemudian disimpan dalam format *csv*. Proses *crawling* dilakukan secara berulang sehingga mendapatkan jumlah data sesuai dengan data yang dibutuhkan. Gbr. 3 merupakan diagram yang menggambarkan proses *crawling* data *twitter*.



Gbr. 3 Proses Crawling Data

B. Preprocessing

Tahap *preprocessing* dilakukan untuk mengubah data mentah hasil proses *crawling* dataset yang kemudian diolah hingga menghasilkan data bersih yang siap digunakan untuk proses selanjutnya. Gbr. 4 merupakan tahapan dari proses *preprocessing* pada penelitian ini.



Gbr. 4 Tahapan Proses Preprocessing

Berikut ini penjelasan mengenai alur tahapan dari Gbr. 4:

- 1) *Cleansing* : Penghapusan karakter yang tidak perlu seperti *tanda baca, angka, retweet, hashtag, tab, new line, black slice, emoticon, chinese word, mention, link, URL, angka, spasi depan dan belakang, double atau single spasi, dan karakter tunggal*.
- 2) *Case Folding* : Proses mengubah semua kata dalam teks yang menggunakan huruf besar menjadi huruf kecil.
- 3) *Tokenizing* : Proses mengubah teks atau kalimat menjadi satuan kata.
- 4) *Normalisasi* : Proses mengubah atau memperbaiki kata yang tidak baku, seperti kata singkatan menjadi kata aslinya.
- 5) *Stopword Removal* : Proses menghilangkan kata-kata dari sebuah kalimat yang tidak bermakna atau tidak mempunyai pengaruh. Contohnya adalah konjungsi seperti (*setelah, sebelum, selesai*), kata keterangan seperti (*sangat, hanya, lebih*), kata bilangan seperti (*beberapa, banyak, sedikit*), kata tugas seperti (*dari, dengan, pada*), dan kata ganti seperti (*itu, ini, kita*).
- 6) *Stemming* : Proses mengubah suatu kata menjadi kata dasarnya.
- 7) *Hapus Data Duplikat* : Proses penghapusan data yang sama.


C. Labelling Data

Pelabelan data adalah proses pemberian label pada sebuah data untuk mengetahui data tersebut masuk dalam kategori kelas positif atau negatif. Dalam penelitian ini, pelabelan dilakukan dengan menggunakan proses *lexicon-based*. Tujuan dari menggunakan proses *lexicon-based* yaitu untuk mempermudah dalam proses pelabelan dalam jumlah banyak.

Tahapan pada proses pelabelan dilakukan dalam dua tahap yaitu dengan proses *TextBlob* dan *VADER (Valance Aware Dictionary and sEntimen Reasor)*. *TextBlob* adalah pustaka *python* dalam pemrosesan bahasa alami (NLP). Penggunaan

textblob untuk labelling sentimen yaitu dengan menentukan *skor polaritas* dan *skor subjektivitas*. *Polaritas* mengacu pada emosi yang diungkapkan dalam kalimat yang dianalisis. Jika *skor polaritas* yaitu -1 berarti bernilai negatif. Jika *skor polaritas* yaitu 1 berarti bernilai positif. *Subjektivitas* adalah sebuah pengekspresian dari sebuah ide atau pandangan seseorang, pemilikan serta emosi yang dituangkan dalam sebuah platform media sosial. *Skor subjektivitas* berkisar antara 0 hingga 1 dimana 0 berarti *objektif* dan 1 berarti *subjektif* [8]. Sedangkan *VADER (Valance Aware Dictionary and sEntimen Reasor)* adalah pustaka *python* yang berfokus pada sentimen media sosial. Nilai *coumpound* diperlukan saat menggunakan labelling *VADER*. Nilai *coumpound* > 0 berarti kelas positif, sedangkan nilai *coumpound* < 0 berarti kelas negatif.

Pelabelan dengan *TextBlob* dan *VADER* untuk analisis sentimen tersedia dalam bahasa Inggris. Artinya data yang diperoleh dari proses *preprocessing* diterjemahkan ke dalam bahasa Inggris sebelum dilakukan analisis sentimen [9]. Alur proses *preprocessing* data yang diterjemahkan ke dalam bahasa Inggris ditunjukkan pada Gbr. 5 di bawah ini.



Gbr. 5 Proses Mengubah data Bahasa Indonesia ke Bahasa Inggris

D. Ekstraksi Fitur

Dalam proses klasifikasi, menghasilkan fitur-fitur yang dapat digunakan biasa disebut dengan ekstraksi fitur. Pada penelitian ini ekstraksi fitur dilakukan dengan menggunakan tiga fitur yaitu *N-Gram*, *TF-IDF* dan gabungan dari *TF-IDF N-Gram*.

1. N-Gram

Fungsi *N-Gram* adalah proses yang umum digunakan dalam pengolahan kata dan bahasa. *N-Gram* digunakan untuk menghubungkan kata sifat umum dan menyorot kata-kata penting dalam dokumen untuk mengekspresikan suasana hati[10]. Selain itu, *N-Gram* digunakan untuk memajukan kata, dan kata yang dimajukan mencakup X jumlah data. Pada penelitian ini, fitur *N-Gram* yang digunakan yaitu *Unigram* dan *Bigram*. Setiap proses *N-Gram* terlebih dahulu diberikan nilai N. Jika nilai N=1 maka disebut *unigram*. Dan jika N=2 disebut dengan *bigram*. Berikut ini rumus untuk menghitung fitur *N-Gram* :

$$Ngrams_k = X - (N - 1) \quad (1)$$

N-gram memiliki beberapa karakteristik diantaranya sebagai berikut [11]:

- Walaupun memiliki kesalahan tekstual, tetapi *N-Gram* dapat berfungsi dengan baik
- N-Gram* hanya membutuhkan penyimpanan yang sederhana dan dapat berjalan secara efisien
- Proses *N-Gram* relatif cepat

2. TF-IDF

Metode untuk perhitungan bobot dari setiap kata yang digunakan adalah *Term Frequency-Inverse Document Frequency (TF-IDF)*. Cara ini efisien, sederhana dan akurat sehingga sering digunakan. Metode *TF-IDF* sering digunakan untuk mengklasifikasikan dan menganalisis data untuk mengetahui berapa kali suatu kata muncul dalam suatu dokumen.

Di bawah ini adalah perhitungan nilai *TF-IDF* untuk setiap kata pada dokumen.

1) Term Frequency (TF)

Frekuensi kemunculan sebuah kata dalam suatu dokumen tertentu disebut *Term Frequency*. Berikut ini adalah rumus untuk menghitung nilai *Term Frequency (TF)*.

$$TF_{t,d} = 1 + \log_{10}(f_{t,d}), f_{t,d} > 0 \mid TF_{t,d} = 0, f_{t,d} = 0 \quad (2)$$

Dimana masing-masing variabel dijelaskan sebagai berikut:

$TF_{t,d}$ = pembobotan lokal kata t pada dokumen d

$f_{t,d}$ = frekuensi kata atau jumlah kata dalam dokumen

2) Document Frequency

Document Frequency adalah jumlah dokumen yang mengandung kata atau istilah.

3) Inverse Document Frequency (IDF)

Inverse Document Frequency adalah cara untuk menghitung berapa kali suatu istilah muncul di seluruh kumpulan teks. Nilai *IDF (Inverse Document Frequency)* dapat dihitung dengan menggunakan rumus berikut.

$$IDF_t = \log\left(\frac{D}{df_t}\right) \quad (3)$$

Berikut ini penjelasan masing-masing variabel:

IDF_t = invers frekuensi dokumen atau bobot

D = jumlah dokumen

df_t = jumlah dokumen yang mengandung kata t

4) TF-IDF

TF-IDF adalah bobot kata yang umum digunakan dalam proses *text mining* dan analisis sentimen. Rumus untuk menghitung *TF-IDF* adalah:

$$W_{t,d} = TF_{t,d} \times IDF_t \quad (4)$$

$$W_{t,d} = TF_{t,d} \times \log\left(\frac{D}{df_t}\right) \quad (5)$$

Dimana:

$W_{t,d}$ = bobot kata

$TF_{t,d}$ = jumlah istilah atau kata dalam dokumen

IDF_t = jumlah kemunculan istilah atau kata

3. TF-IDF N-Gram

TF-IDF N-Gram adalah kombinasi dari ekstraksi fitur *TF-IDF* dan *N-Gram*. Dengan menerapkan metode *TF-IDF N-Gram* dapat meningkatkan kualitas dari fitur yang dihasilkan. Proses *TF-IDF N-Gram* dilakukan dengan melakukan tokenisasi pada kata-kata dalam sebuah kalimat. Setelah itu dilakukan proses pembobotan *TF-IDF*.

E. Split Data

Proses *split* data hasil proses fitur *N-Gram*, *TF-IDF*, dan gabungan *TF-IDF N-Gram* dibagi menjadi data *pelatihan* dan data *uji*. Data *pelatihan* digunakan untuk membuat model klasifikasi algoritma, sedangkan data *pengujian* digunakan untuk proses pengujian model. Tabel I merupakan pembagian dari data *pelatihan* dan data *uji*.

TABEL I
PEMBAGIAN DATA TRAIN DAN DATA TEST

Data Train	Data Test
90	10
80	20
70	30
60	40
50	50

F. Algoritma Klasifikasi

Algoritma klasifikasi yang digunakan dalam penelitian ini adalah sebagai berikut:

1.) K-Nearest Neighbor (K-NN)

Algoritma *K-Nearest Neighbor (K-NN)* dapat digunakan dalam proses klasifikasi, yaitu berdasarkan data yang jaraknya paling dekat dengan objek [12]. Pengklasifikasi *K-Nearest Neighbor* biasanya didasarkan pada jarak *Euclidean* antara *sampel uji* dan *sampel latih* yang ditentukan.

Perhitungan *Euclidean* pada -1 dimensional space sebagai berikut:

$$d_i = \sqrt{\sum_{i=1}^n (x_{2i} - x_{1i})^2} \quad (6)$$

Keterangan:

x_1 = data sampel

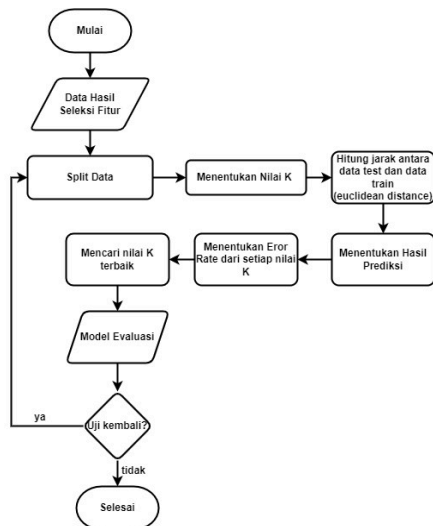
x_2 = data uji

i = data variabel

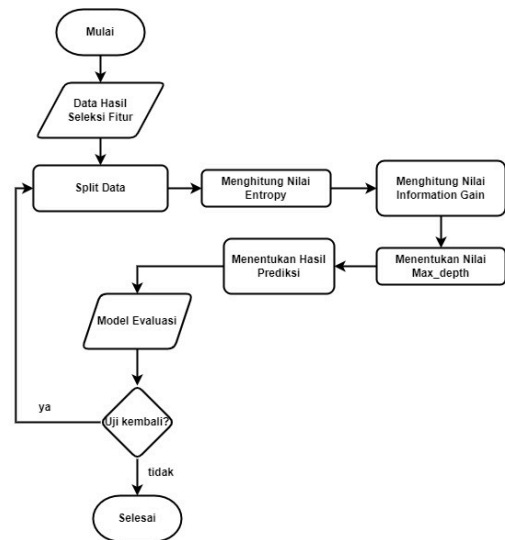
d = jarak

n = data dimensi

Alur proses algoritma *K-Nearest Neighbor (K-NN)* pada sistem ditunjukkan pada Gbr. 6 berikut.



Gbr. 6 Alur Proses K-NN



Gbr. 7 Alur Proses Decision Tree

2.) Decision Tree

Decision Tree juga dikenal sebagai pohon keputusan, adalah suatu metode klasifikasi yang berbentuk struktur pohon. Keuntungan menggunakan pohon keputusan adalah memungkinkan proses pengambilan keputusan yang kompleks dapat diuraikan menjadi proses yang lebih sederhana, sehingga memudahkan untuk menemukan solusi masalah pengambilan keputusan [13].

Perhitungan dilakukan menggunakan metode *Decision Tree* melalui langkah-langkah berikut:

- *Menentukan Nilai Entropy*

Perhitungan untuk menentukan nilai *Entropy* adalah:

$$Entropy(S) = \sum_{i=1}^n -p_i * \log_2 p_i \quad (7)$$

Keterangan:

S = jumlah kasus

n = banyaknya pembagian S

pi = perbandingan Si terhadap S

- *Information Gain*

Untuk menghitung nilai *gain*, menggunakan rumus berikut ini:

$$Gain(S, A) = Entropy(S) - \sum_{i=1}^n \frac{s_i}{s} * Entropy(S_i) \quad (8)$$

Keterangan:

S = jumlah kasus

A = atribut

n = banyaknya pembagian A

|Si| = banyaknya kasus pada partisi ke-i

|S| = banyaknya kasus dalam S

Alur proses dari algoritma *Decision Tree* pada sistem ditunjukkan pada Gbr. 7 berikut.

G. Pengujian Model

Untuk mengetahui keakuratan model klasifikasi yang dibuat, dilakukan pengujian terhadap model. Pengujian dilakukan setelah dilakukan *split data*, dengan data yang digunakan yaitu data *uji*.

H. Evaluasi Model

Tahap evaluasi model dilakukan untuk mengevaluasi kinerja model yang telah dihasilkan. Evaluasi model dilakukan dengan menggunakan proses *confusion matrix* dan tabel akurasi untuk setiap model. *Confusion matrix* adalah metode pengukuran kinerja untuk menampilkan dan membandingkan nilai hasil prediksi dan nilai asli yang digunakan untuk mengetahui hasil performa. Kemudian dilakukan perhitungan nilai *accuracy*, *recall*, *precision*, dan *f1-score*.

Berikut ini penjelasan nilai performa pada *confusion matrix*:

- 1) Akurasi adalah seberapa dekat nilai prediksi dengan nilai aslinya. Dengan kata lain, prediksi positif dibagi dengan jumlah nilai asli dan jumlah nilai prediksi.

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

- 2) Presisi adalah jumlah dokumen relevan yang diambil dari sistem. Dengan kata lain, presisi yaitu jumlah positif sebenarnya dibagi dengan total prediksi positif.

$$Precision = \frac{TP}{TP + FP} \quad (10)$$

- 3) Recall adalah tingkat keberhasilan sistem dalam memanggil dokumen yang relevan. Dengan kata lain, recall yaitu jumlah nilai prediksi sebenarnya dibagi dengan nilai prediksi sebenarnya dan nilai negatif palsu.

$$Recall = \frac{TP}{TP + FN} \quad (11)$$

- 4) F-Measure atau F1 skor merupakan perhitungan yang menggabungkan nilai precision dan recall.

$$F1 = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (12)$$

III. HASIL DAN PEMBAHASAN

Metode *K-Nearest Neighbor* (K-NN) dan *Decision Tree* digunakan dalam penelitian ini untuk menentukan bagaimana masyarakat mengutarakan pendapatnya di media sosial dengan dilakukan analisis sentimen terhadap informasi pasca bencana alam. Sudahkah masyarakat memberikan komentar yang berempati dengan memberikan komentar positif atau sebaliknya berkomentar negatif. Penelitian ini juga bertujuan untuk membandingkan hasil akurasi dari metode *K-Nearest Neighbor* (K-NN) dan *Decision Tree* dengan penambahan fitur *N-Gram*, *TF-IDF* dan gabungan dari *TF-IDF N-Gram*.

A. Pengambilan Data

Data dikumpulkan melalui proses *crawling* data *tweet*. Kategori yang terdiri dari *angin puting beliung*, *banjir*, *gempa*, *tsunami* atau *gelombang pasang*, *tanah longsor*, dan *gunung meletus* memiliki total 400 data per kategori. Kemudian data dari masing-masing kategori dijadikan 1 file csv dengan data yang digunakan yaitu berisi nama pengguna, isi *tweet*, dan kategori sehingga menghasilkan data sebanyak 2400 dataset. Gbr. 8 merupakan hasil dari proses *crawling dataset* setelah data digabung menjadi 1 file csv.

	nama-pengguna	teks	katagori
0	arthaamk	Danrem 033/WP Brigjen TNI Yudi Yulistianto Tin...	angin beliung
1	iwanksantoso95	giat bhabinakamtibmas polsek sipispis melaksana...	angin beliung
2	lukyypradana	@elisabetrii masuk angin puting beliung po	angin beliung
3	sotongbakar3	@MentalHealerid Badai tomado puting beliung a...	angin beliung
4	titahnews1318	Danrem 033/WP Brigjen TNI Yudi Yulistianto Tin...	angin beliung

Gbr. 8 Hasil Proses Crawling Dataset

B. Hasil Preprocessing

Proses *preprocessing* dilakukan untuk membuat data yang siap diolah ke tahap selanjutnya. Contoh dari proses *preprocessing* seperti Tabel II berikut ini.

TABEL II
CONTOH HASIL PROSES PREPROCESSING

Tweet Asli	
Guru bhs inggris gue kayak nya hujan angin puting beliung pun tetep aja masuk	
Proses Preprocessing	Hasil
Cleansing	Guru bhs inggris gue kayak nya hujan angina puting beliung pun tetep aja masuk
Case Folding	guru bhs inggris gue kayak nya hujan angina puting beliung pun tetep aja masuk
Tokenizing	['guru','bhs','inggris','gue','kayak','nya','hujan','angin','puting','beliung','pun','tetep','aja','masuk']
Normalisasi	['guru','bahasa','inggris','saya','seperti','nya','hujan','angin','puting','beliung','pun','tetap','saja','masuk']
Stopword Removal	['guru','bahasa','inggris','hujan','angin','puting','beliung','masuk']

Stemming	['guru','bahasa','inggris','hujan','angin','puting','beliung','masuk']
Hasil Akhir	
guru bahasa inggris hujan angin puting beliung masuk	

Hasil dari proses *preprocessing* data yaitu dari jumlah dataset sebanyak 2400 data menjadi 1705 data setelah dilakukan *remove data duplicate* yang selanjutnya data siap untuk diproses ke tahap selanjutnya.

C. Hasil Labelling Data

Proses labelling dataset menggunakan kamus *lexicon-based*. Pertama dilakukan proses mengubah data bahasa Indonesia menjadi bahasa Inggris. Berikut ini Gbr. 9 merupakan hasil dari proses *translate* data.

	tweet
0	commander of military resort wira pratama brig...
1	active bhayangkara building safe and orderly s...
2	in a tornado
3	storm tornado tornado wind storm evening sky h...
4	crazy cool layouts hurricane tornado hospital ...
5	hate
6	the wind is silent, the feeling of a whirlwind...
7	hey, what's the tornado, the hot waru
8	boys and girls, behhh, they hit the bardir bom...
9	the rain is really heavy, the wind is thunder,...

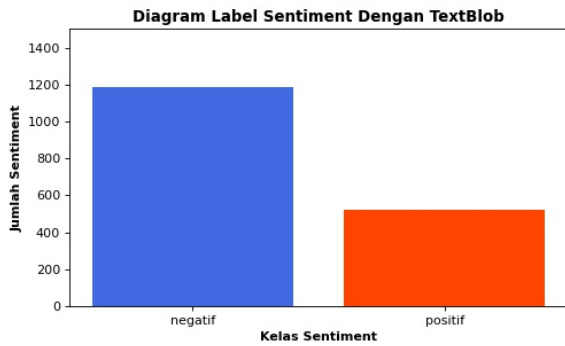
Gbr. 9 Hasil Translate Dataset

Hasil dari proses *translate* dataset, kemudian dilakukan proses labelling data dengan tahap *TextBlob* dan *VADER*. Proses labelling *textblob* dilakukan dengan menghitung nilai *skor subjektivitas* dan *skor polaritas*. Gbr. 10 merupakan hasil dari proses labelling *textblob*.

tweet	Subjectivity	Polarity	Sentiment
0 military resort commander Wira Pratama brigadi...	0.533333	-0.283333	Negatif
1 Bhayangkara is active in building a safe and o...	0.425000	0.216667	Positif
2 in a tornado	0.000000	0.000000	Negatif
3 storm tornado tornado wind storm evening sky h...	0.500000	-0.200000	Negatif
4 crazy cool layout hurricane hurricane tornado ...	0.775000	-0.125000	Negatif
...
1700 I hope people care about the mental health of ...	0.300000	-0.200000	Negatif
1701 bm the tide of the sea returns, umno wants pru...	0.100000	0.200000	Positif
1702 good evening tomorrow's weather forecast Sunda...	0.511111	0.103704	Positif
1703 tidal waves understand	0.000000	0.000000	Negatif
1704 silent body, echo of the song of longing, hum,...	0.100000	0.000000	Negatif

Gbr. 10 Hasil Labelling Textblob

Dengan menggunakan fungsi *TextBlob*, dihasilkan 518 kelas sentimen positif dan 1187 kelas sentimen negatif dari 1705 data *tweet*. Gbr. 11 merupakan visualisasi dari hasil pelabelan sentimen *TextBlob*.



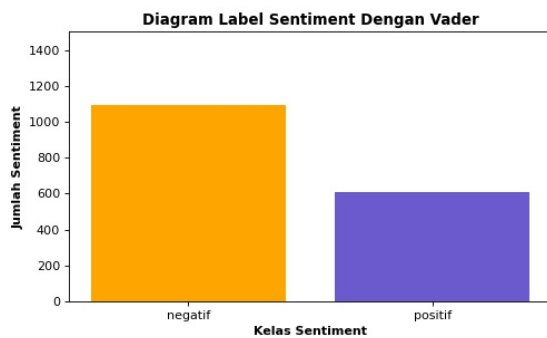
Gbr. 11 Visualisasi Diagram Labelling Textblob

Selanjutnya, proses labelling dengan tahap *VADER* dengan menentukan nilai *skor compound*. Gbr. 12 adalah hasil dari proses labelling *VADER*.

	tweet	Compound-Score	Sentiment
0	military resort commander Wira Pratama brigadi...	0.0000	Negatif
1	Bhayangkara is active in building a safe and o...	0.8555	Positif
2	in a tornado	0.0000	Negatif
3	storm tornado tornado wind storm evening sky h...	0.6369	Positif
4	crazy cool layout hurricane hurricane tornado ...	-0.0258	Negatif
...
1700	I hope people care about the mental health of ...	0.7269	Positif
1701	bm the tide of the sea returns, umno wants pru...	0.0000	Negatif
1702	good evening tomorrow's weather forecast Sunda...	0.7906	Positif
1703	tidal waves understand	0.0000	Negatif
1704	silent body, echo of the song of longing, hum,...	0.4215	Positif

Gbr. 12 Hasil Labelling VADER

Dengan menggunakan fungsi *VADER*, diperoleh 629 kelas sentimen positif dan 1076 kelas sentimen negatif dari data sebanyak 1705 data *tweet*. Gbr. 13 merupakan visualisasi dari hasil pelabelan sentimen *VADER*.



Gbr. 13 Visualisasi Diagram Labelling VADER

D. Hasil Pengujian Data Split

Dalam penelitian ini, data dibagi menjadi data *latih* dan data *uji*. Data *pelatihan* digunakan untuk melatih performa model yang dibuat. Sedangkan data *uji* digunakan untuk menguji model yang dibuat. Pengujian dilakukan dengan menggunakan metode *K-Nearest Neighbor* dan *Decision Tree*. Hasil pengujian menghasilkan nilai *accuracy*, *precision*, *recall*, dan *f-1 score*.

Hasil pengujian untuk data *train* dan data *test* metode *K-Nearest Neighbor* data labelling *textblob* ditunjukkan pada Tabel III.

TABEL III
HASIL PENGUJIAN METODE *K-NEAREST NEIGHBOR TEXTBLOB*

Split Data	Nilai K	Accuracy	Precision	Recall	F-1 Score
90:10	1	78,94%	72,00%	38,30%	50,00%
80:20	5	73,31%	80,00%	12,00%	20,87%
70:30	1	74,02%	70,83%	22,22%	33,83%
60:40	1	74,34%	79,37%	23,58%	36,36%
50:50	1	74,91%	76,71%	22,13%	34,36%

Berdasarkan hasil pengujian pada Tabel III, metode *K-NN* dengan data labelling *textblob*, memiliki nilai akurasi tertinggi dengan rasio 90:10. Nilai K terbaik diperoleh pada $k=1$ dengan nilai *accuracy* sebesar 78,94%, *precision* 72%, *recall* 38,30%, dan *f-1 score* 50%.

Hasil pengujian *split data* metode *K-NN* menggunakan fitur *TF-IDF* data labelling *textblob* ditunjukkan pada Tabel IV di bawah ini.

TABEL IV
HASIL PENGUJIAN METODE *K-NEAREST NEIGHBOR TF-IDF TEXTBLOB*

Split Data	Nilai K	Accuracy	Precision	Recall	F-1 Score
90:10	10	78,36%	85,71%	25,53%	39,34%
80:20	9	75,95%	78,13%	25,00%	37,88%
70:30	5	74,80%	65,79%	32,68%	43,67%
60:40	7	73,46%	67,42%	28,30%	39,87%
50:50	15	74,91%	72,94%	24,51%	36,69%

Berdasarkan hasil pengujian pada Tabel IV, metode *K-NN* dengan fitur *TF-IDF* untuk data labelling *textblob*, memiliki akurasi tertinggi pada rasio 90:10. Nilai K terbaik adalah $k=10$ dengan nilai *accuracy* sebesar 78,36%, *precision* 85,71%, *recall* 25,53%, dan *f-1 score* 39,34%.

Hasil pengujian *split data* metode *K-NN* menggunakan fitur *unigram* data labelling *textblob* ditunjukkan pada Tabel V.

TABEL V
HASIL PENGUJIAN METODE *K-NEAREST NEIGHBOR UNIGRAM TEXTBLOB*

Split Data	Nilai K	Accuracy	Precision	Recall	F-1 Score
90:10	1	78,95%	72,00%	38,30%	50,00%
80:20	5	73,31%	100,00%	12,00%	20,87%
70:30	1	74,02%	70,83%	22,22%	33,83%
60:40	1	74,34%	79,37%	23,58%	36,36%
50:50	1	74,91%	76,71%	22,13%	34,36%

Berdasarkan hasil pengujian pada Tabel V, metode *K-NN* dengan fitur *unigram* pada data labelling *textblob*, memiliki akurasi tertinggi pada rasio 90:10. Nilai K terbaik adalah $k=1$ dengan nilai *accuracy* sebesar 78,95%, *precision* 72%, *recall* 38,30%, dan *f-1 score* 50%.

Hasil pengujian *split data* metode *K-NN* dengan fitur *bigram* data labelling *textblob* ditunjukkan pada Tabel VI.

TABEL VI
HASIL PENGUJIAN METODE *K-NEAREST NEIGHBOR BIGRAM TEXTBLOB*

Split Data	Nilai K	Accuracy	Precision	Recall	F-1 Score
90:10	1	76,61%	100,00%	14,89%	25,93%
80:20	3	73,02%	83,33%	10,00%	17,86%
70:30	1	72,27%	92,31%	78,43%	14,46%
60:40	1	71,26%	94,44%	80,19%	14,78%
50:50	1	72,10%	82,61%	75,10%	13,77%

Berdasarkan hasil pengujian pada Tabel VI, metode *K-NN* dengan fitur *bigram* pada data labelling *textblob*, memiliki nilai akurasi tertinggi pada rasio 90:10. Nilai K terbaik k=1 dengan nilai *accuracy* 76,61%, *precision* 100%, *recall* 14,89%, dan *f-1 score* 25,93%.

Hasil pengujian *split data* metode *K-NN* fitur *TF-IDF Unigram* data labelling *textblob* dapat dilihat pada Tabel VII.

TABEL VII
HASIL PENGUJIAN METODE *K-NEAREST NEIGHBOR TF-IDF UNIGRAM TEXTBLOB*

Split Data	Nilai K	Accuracy	Precision	Recall	F-1 Score
90:10	10	78,36%	85,71%	25,53%	39,34%
80:20	7	75,95%	72,50%	29,00%	41,43%
70:30	5	74,61%	64,94%	32,68%	43,48%
60:40	5	73,31%	65,31%	30,19%	41,29%
50:50	3	74,79%	62,34%	37,94%	47,17%

Berdasarkan hasil pengujian pada Tabel VII, metode *K-NN* dengan fitur *TF-IDF Unigram* data labelling *textblob*, memiliki nilai akurasi tertinggi pada rasio 90:10. Nilai K terbaik yaitu k=10 dengan nilai *accuracy* sebesar 78,36%, *precision* sebesar 85,71%, *recall* sebesar 25,53%, dan *f-1 score* sebesar 39,34%.

Hasil pengujian *split data* metode *K-NN* fitur *TF-IDF Bigram* data labelling *textblob* dapat dilihat pada Tabel VIII.

TABEL VIII
HASIL PENGUJIAN METODE *K-NEAREST NEIGHBOR TF-IDF BIGRAM TEXTBLOB*

Split Data	Nilai K	Accuracy	Precision	Recall	F-1 Score
90:10	1	76,61%	100,00%	14,89%	25,93%
80:20	3	73,31%	90,91%	10,00%	18,02%
70:30	1	72,27%	92,31%	78,43%	14,46%
60:40	1	71,26%	94,44%	80,19%	14,78%
50:50	1	72,10%	85,71%	71,15%	13,14%

Berdasarkan hasil pengujian pada Tabel VIII, metode *K-NN* dengan fitur *TF-IDF Bigram* pada data labelling *textblob*,

memiliki akurasi tertinggi pada rasio 90:10. Nilai K terbaik k=1 dengan nilai *accuracy* 76,61%, *precision* 100%, *recall* 14,89%, dan *f-1 score* 25,93%.

Hasil pengujian *split data* dengan metode *K-NN* dengan data labelling *VADER* ditunjukkan pada Tabel IX.

TABEL IX
HASIL PENGUJIAN METODE *K-NEAREST NEIGHBOR VADER*

Split Data	Nilai K	Accuracy	Precision	Recall	F-1 Score
90:10	1	64,91%	61,36%	38,57%	47,37%
80:20	2	63,64%	76,00%	13,87%	23,46%
70:30	1	68,75%	75,32%	29,15%	42,03%
60:40	1	68,48%	72,57%	30,83%	43,27%
50:50	1	66,71%	64,71%	32,93%	43,65%

Berdasarkan hasil pengujian pada Tabel IX, metode *K-NN* data labelling *VADER*, memiliki akurasi tertinggi pada rasio 70:30. Nilai K terbaik adalah k=1 dengan nilai *accuracy* 68,75%, *precision* 75,32%, *recall* 29,15%, dan *f-1 score* 42,03%.

Hasil pengujian *split data* dengan metode *K-NN TF-IDF* dengan data labelling *VADER* dapat dilihat pada Tabel X.

TABEL X
HASIL PENGUJIAN METODE *K-NEAREST NEIGHBOR TF-IDF VADER*

Split Data	Nilai K	Accuracy	Precision	Recall	F-1 Score
90:10	13	69,01%	79,31%	32,86%	46,46%
80:20	15	69,79%	76,56%	35,77%	48,76%
70:30	5	70,51%	69,67%	42,71%	52,96%
60:40	15	69,06%	69,50%	36,84%	48,16%
50:50	13	69,87%	74,52%	35,03%	47,66%

Berdasarkan hasil dari Tabel X, metode *K-NN TF-IDF* data labelling *VADER*, memiliki akurasi tertinggi pada rasio 70:30. Nilai K terbaik adalah k=5 dengan nilai *accuracy* 70,51%, *precision* 69,67%, *recall* 42,71%, dan *f-1 score* 52,96%.

Hasil pengujian *split data* dengan metode *K-NN Unigram* data labelling *VADER* ditunjukkan pada Tabel XI.

TABEL XI
HASIL PENGUJIAN METODE *K-NEAREST NEIGHBOR UNIGRAM VADER*

Split Data	Nilai K	Accuracy	Precision	Recall	F-1 Score
90:10	5	64,91%	81,25%	18,57%	30,23%
80:20	2	63,64%	76,00%	13,87%	23,46%
70:30	1	68,75%	75,32%	29,15%	42,03%
60:40	1	68,48%	72,57%	30,83%	43,27%
50:50	1	66,71%	64,71%	32,93%	43,65%

Berdasarkan hasil dari Tabel XI, metode *K-NN Unigram* data labelling *VADER*, memiliki akurasi tertinggi pada rasio

70:30. Nilai K terbaik adalah k=1 dengan nilai *accuracy* sebesar 68,75%, *precision* sebesar 75,32%, *recall* sebesar 29,15%, dan *f-1 score* sebesar 42,03%.

Hasil pengujian *split data* dengan metode *K-NN Bigram* dengan data labelling *VADER* dapat dilihat pada Tabel XII.

TABEL XII
HASIL PENGUJIAN METODE *K-NEAREST NEIGHBOR BIGRAM VADER*

Split Data	Nilai K	Accuracy	Precision	Recall	F-1 Score
90:10	7	61,40%	100,00%	57,14%	10,81%
80:20	3	64,22%	94,12%	11,68%	20,78%
70:30	1	64,65%	90,91%	10,05%	18,10%
60:40	1	64,66%	90,32%	10,53%	18,86%
50:50	1	64,01%	88,57%	9,28%	16,80%

Berdasarkan hasil dari Tabel XII, metode *K-NN* data labelling *VADER*, memiliki akurasi tertinggi pada rasio 60:40. Nilai K terbaik adalah k=1 dengan nilai *accuracy* sebesar 64,66%, *precision* sebesar 90,32%, *recall* sebesar 10,53%, dan *f-1 score* sebesar 18,86%.

Hasil pengujian *split data* dengan metode *K-NN TF-IDF Unigram* data labelling *VADER* ditunjukkan pada Tabel XIII.

TABEL XIII
HASIL PENGUJIAN METODE *K-NEAREST NEIGHBOR TF-IDF UNIGRAM VADER*

Split Data	Nilai K	Accuracy	Precision	Recall	F-1 Score
90:10	13	69,01%	79,31%	32,86%	46,46%
80:20	15	70,38%	80,00%	35,04%	48,73%
70:30	13	70,51%	75,53%	35,68%	48,46%
60:40	15	69,35%	70,21%	37,22%	48,65%
50:50	13	69,52%	72,84%	35,33%	47,58%

Berdasarkan hasil dari Tabel XIII, metode *K-NN* data labelling *VADER*, memiliki nilai akurasi tertinggi pada rasio 80:20. Nilai K terbaik yaitu k=15 dengan nilai *accuracy* sebesar 70,38%, *precision* sebesar 80%, *recall* sebesar 35,04%, dan *f-1 score* sebesar 48,73%.


Hasil pengujian *split data* dengan metode *K-NN TF-IDF Bigram* data labelling *VADER* ditunjukkan pada Tabel XIV.

TABEL XIV
HASIL PENGUJIAN METODE *K-NEAREST NEIGHBOR TF-IDF BIGRAM VADER*

Split Data	Nilai K	Accuracy	Precision	Recall	F-1 Score
90:10	5	61,99%	77,78%	10,00%	17,72%
80:20	3	63,93%	100,00%	10,22%	18,54%
70:30	1	64,65%	100,00%	9,05%	16,59%
60:40	1	64,52%	100,00%	9,02%	16,55%
50:50	1	64,13%	100,00%	8,38%	15,47%

Berdasarkan hasil dari Tabel XIV, metode *K-NN TF-IDF Bigram* data labelling *VADER*, memiliki nilai akurasi tertinggi pada rasio 70:30. Nilai K terbaik adalah k=1 dengan nilai *accuracy* sebesar 64,65%, *precision* sebesar 100%, *recall* sebesar 90,45%, dan *f-1 score* sebesar 16,59%.

Hasil pengujian dari metode *K-NN* dengan nilai akurasi terbaik dapat dilihat pada visualisasi Gbr.14.



Gbr. 14 Visualisasi Akurasi Terbaik dari setiap skenario Hasil Pengujian metode K-Nearest Neighbor (K-NN)

Tabel XV di bawah ini menunjukkan hasil pengujian data *train* dan data *test* menggunakan metode *Decision Tree TextBlob*.

TABEL XV
HASIL PENGUJIAN METODE *DECISION TREE TEXTBLOB*

Split Data	Accuracy	Precision	Recall	F-1 Score
90:10	80,12%	88,24%	31,91%	46,88%
80:20	79,47%	94,12%	32,00%	47,76%
70:30	78,52%	95,74%	29,41%	45,00%
60:40	78,45%	95,77%	32,08%	48,06%
50:50	79,37%	95,29%	32,02%	47,93%

Berdasarkan pengujian Tabel XV, metode *Decision Tree* labelling *textblob*, memiliki nilai *accuracy* tertinggi pada rasio 90:10 yaitu sebesar 80,12%, nilai *precision* sebesar 88,24%, *recall* sebesar 31,91%, dan *f-1 score* sebesar 46,88%.

Hasil pengujian *split data* dengan menggunakan metode *Decision Tree TF-IDF TextBlob* ditunjukkan pada Tabel XVI.

TABEL XVI
HASIL PENGUJIAN METODE *DECISION TREE TF-IDF TEXTBLOB*

Split Data	Accuracy	Precision	Recall	F-1 Score
90:10	81,29%	94,12%	34,04%	50,00%
80:20	79,47%	94,12%	32,00%	47,76%
70:30	78,52%	97,78%	28,76%	44,44%
60:40	78,30%	95,71%	31,60%	47,52%
50:50	79,25%	95,24%	31,62%	47,77%

Berdasarkan pengujian pada Tabel XVI, metode *Decision Tree TF-IDF* labelling *textblob*, memiliki *accuracy* tertinggi pada rasio 90:10 yaitu sebesar 81,29%, nilai *precision* sebesar 94,12%, *recall* sebesar 34,04%, dan *f-1 score* sebesar 50%.

Hasil pengujian *split data* menggunakan metode *Decision Tree Unigram TextBlob* dapat dilihat pada Tabel XVII.

TABEL XVII
HASIL PENGUJIAN METODE *DECISION TREE UNIGRAM TEXTBLOB*

Split Data	Accuracy	Precision	Recall	F-1 Score
90:10	80,12%	88,24%	31,91%	46,88%
80:20	79,47%	94,12%	32,00%	47,61%
70:30	78,52%	95,74%	29,41%	45,00%
60:40	78,45%	95,77%	32,08%	48,06%
50:50	79,37%	95,29%	32,02%	47,93%

Berdasarkan pengujian pada Tabel XVII, metode *Decision Tree Unigram* labelling *textblob*, memiliki nilai *accuracy* tertinggi pada rasio 90:10 yaitu sebesar 80,12%, nilai *precision* sebesar 88,24%, *recall* sebesar 31,91%, dan *f-1 score* sebesar 46,88%.

Hasil pengujian *split data* menggunakan metode *Decision Tree Bigram TextBlob* dapat dilihat pada Tabel XVIII.

TABEL XVIII
HASIL PENGUJIAN METODE *DECISION TREE BIGRAM TEXTBLOB*

Split Data	Accuracy	Precision	Recall	F-1 Score
90:10	75,44%	100,00%	10,64%	19,23%
80:20	74,78%	100,00%	14,00%	24,56%
70:30	73,05%	80,00%	13,07%	22,47%
60:40	73,17%	93,93%	14,62%	25,31%
50:50	73,97%	94,29%	13,04%	22,92%

Berdasarkan pengujian Tabel XVIII, metode *Decision Tree Bigram* labelling *textblob*, memiliki nilai *accuracy* tertinggi pada rasio 90:10 yaitu sebesar 75,44%, nilai *precision* sebesar 100%, *recall* sebesar 10,64%, dan *f-1 score* sebesar 19,23%.

Hasil pengujian *split data* menggunakan metode *Decision Tree TF-IDF Unigram TextBlob* dapat dilihat pada Tabel XIX.

TABEL XIX
HASIL PENGUJIAN METODE *DECISION TREE TF-IDF UNIGRAM TEXTBLOB*

Split Data	Accuracy	Precision	Recall	F-1 Score
90:10	81,29%	94,12%	34,04%	50,00%
80:20	79,47%	94,12%	32,00%	47,76%
70:30	78,52%	97,78%	28,76%	44,44%
60:40	78,30%	95,71%	31,60%	47,52%
50:50	79,25%	95,24%	31,62%	47,77%

Berdasarkan pengujian Tabel XIX, metode *Decision Tree Unigram* labelling *textblob*, memiliki nilai *accuracy* tertinggi

pada rasio 90:10 yaitu sebesar 81,29%, nilai *precision* sebesar 94,12%, *recall* sebesar 34,04%, dan *f-1 score* sebesar 50%.

Hasil pengujian *split data* menggunakan metode *Decision Tree TF-IDF Bigram TextBlob* ditunjukkan pada Tabel XX.

TABEL XX
HASIL PENGUJIAN METODE *DECISION TREE TF-IDF BIGRAM TEXTBLOB*

Split Data	Accuracy	Precision	Recall	F-1 Score
90:10	75,44%	100,00%	10,64%	19,23%
80:20	73,90%	86,66%	13,00%	22,61%
70:30	72,66%	84,21%	10,46%	18,65%
60:40	72,73%	88,24%	14,15%	24,39%
50:50	73,86%	91,67%	13,04%	22,84%

Berdasarkan pengujian pada Tabel XX, metode *Decision Tree TF-IDF Bigram* data labelling *TextBlob*, memiliki *accuracy* tertinggi pada rasio 90:10 sebesar 75,44%, *precision* 100%, *recall* 10,64%, dan *f-1 score* 19,23%.

Hasil pengujian *split data* metode *Decision Tree* dengan data labelling *VADER* dapat dilihat pada Tabel XXI.

TABEL XXI
HASIL PENGUJIAN METODE *DECISION TREE VADER*

Split Data	Accuracy	Precision	Recall	F-1 Score
90:10	68,42%	90,00%	25,71%	40,00%
80:20	69,79%	92,50%	27,01%	41,81%
70:30	69,53%	89,09%	24,62%	38,58%
60:40	69,65%	86,42%	26,32%	40,35%
50:50	69,52%	86,27%	26,35%	40,37%

Berdasarkan hasil dari Tabel XXI, metode *Decision Tree* data labelling *VADER*, memiliki *accuracy* tertinggi pada rasio 80:20 yaitu sebesar 69,79%, *precision* sebesar 92,50%, *recall* sebesar 27,01%, dan *f-1 score* sebesar 41,81%.

Hasil pengujian *split data* dengan metode *Decision Tree TF-IDF* data labelling *VADER* ditunjukkan pada Tabel XXII

TABEL XXII
HASIL PENGUJIAN METODE *DECISION TREE TF-IDF VADER*

Split Data	Accuracy	Precision	Recall	F-1 Score
90:10	68,42%	90,00%	25,71%	40,00%
80:20	70,09%	92,68%	27,74%	42,70%
70:30	68,95%	87,04%	23,62%	37,15%
60:40	69,35%	86,08%	25,56%	39,42%
50:50	69,64%	85,71%	26,95%	41,00%

Berdasarkan hasil dari Tabel XXII, metode *Decision Tree TF-IDF* labelling *VADER*, memiliki *accuracy* tertinggi pada rasio 80:20 yaitu sebesar 70,09%, *precision* sebesar 92,68%, *recall* sebesar 27,74%, dan *f-1 score* sebesar 42,70%.

Hasil pengujian *split data* metode *Decision Tree Unigram* dengan data labelling *VADER* ditunjukkan pada Tabel XXIII.

TABEL XXIII
HASIL PENGUJIAN METODE *DECISION TREE UNIGRAM VADER*

Split Data	Accuracy	Precision	Recall	F-1 Score
90:10	68,42%	90,00%	25,71%	40,00%
80:20	69,79%	92,50%	27,01%	41,81%
70:30	69,53%	89,09%	24,62%	38,58%
60:40	69,65%	86,42%	26,32%	40,35%
50:50	69,52%	86,27%	26,35%	40,37%

Berdasarkan pengujian pada Tabel XXIII, metode *Decision Tree Unigram* data labelling *VADER*, memiliki *accuracy* tertinggi pada rasio 80:20 sebesar 69,79%, *precision* sebesar 92,50%, *recall* sebesar 27,01%, dan *f-1 score* sebesar 41,81.

Hasil pengujian *split data* metode *Decision Tree Bigram* dengan data labelling *VADER* ditunjukkan pada Tabel XXIV.

TABEL XXIV
HASIL PENGUJIAN METODE *DECISION TREE BIGRAM VADER*

Split Data	Accuracy	Precision	Recall	F-1 Score
90:10	62,57%	100,00%	8,57%	15,78%
80:20	63,34%	92,86%	9,49%	17,22%
70:30	64,26%	94,44%	5,43%	15,67%
60:40	64,52%	87,50%	10,52%	18,79%
50:50	64,48%	89,74%	10,48%	18,77%

Berdasarkan pengujian Tabel XXIV, metode *Decision Tree Bigram* data labelling *VADER*, memiliki nilai *accuracy* tertinggi pada rasio 60:40 yaitu sebesar 64,52%, *precision* sebesar 87,50%, *recall* sebesar 10,52%, dan *f-1 score* sebesar 18,79%.

Hasil pengujian *split data* metode *Decision Tree TF-IDF Unigram* data labelling *VADER* dapat dilihat pada Tabel XXV.

TABEL XXV
HASIL PENGUJIAN METODE *DECISION TREE TF-IDF UNIGRAM VADER*

Split Data	Accuracy	Precision	Recall	F-1 Score
90:10	68,42%	90,00%	25,71%	40,00%
80:20	70,88%	92,68%	27,74%	42,70%
70:30	68,95%	87,04%	23,62%	37,15%
60:40	69,35%	86,08%	25,56%	39,42%
50:50	69,64%	85,71%	26,96%	41,00%

Berdasarkan pengujian Tabel XXV, metode *Decision Tree TF-IDF Unigram* labelling *VADER*, memiliki nilai *accuracy* tertinggi pada rasio 80:20 yaitu sebesar 70,88%, nilai

precision sebesar 92,68%, *recall* sebesar 27,74%, dan *f-1 score* sebesar 42,70%.

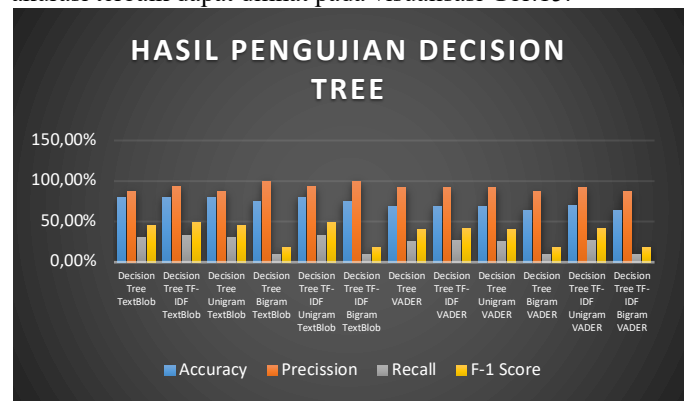
Hasil pengujian *split data* dengan metode *Decision Tree TF-IDF Bigram* labelling *VADER* dapat dilihat pada Tabel XXVI.

TABEL XXVI
HASIL PENGUJIAN METODE *DECISION TREE TF-IDF BIGRAM VADER*

Split Data	Accuracy	Precision	Recall	F-1 Score
90:10	62,57%	100,00%	8,57%	15,79%
80:20	63,34%	92,86%	9,49%	17,22%
70:30	64,26%	94,44%	8,54%	15,67%
60:40	64,52%	87,50%	10,53%	18,79%
50:50	63,89%	82,50%	9,88%	17,65%

Berdasarkan hasil dari Tabel XXVI, metode *Decision Tree TF-IDF Bigram* data labelling *VADER*, memiliki nilai *accuracy* tertinggi pada rasio 60:40 yaitu sebesar 64,52%, *precision* 87,50%, *recall* 10,53%, dan *f-1 score* 18,79%.

Hasil pengujian dari metode *Decision Tree* dengan nilai akurasi terbaik dapat dilihat pada visualisasi Gbr.15.



Gbr. 15 Visualisasi Akurasi Terbaik dari setiap skenario Hasil Pengujian metode *Decision Tree*

E. Hasil Perbandingan Metode *K-Nearest Neighbor* dan *Decision Tree*

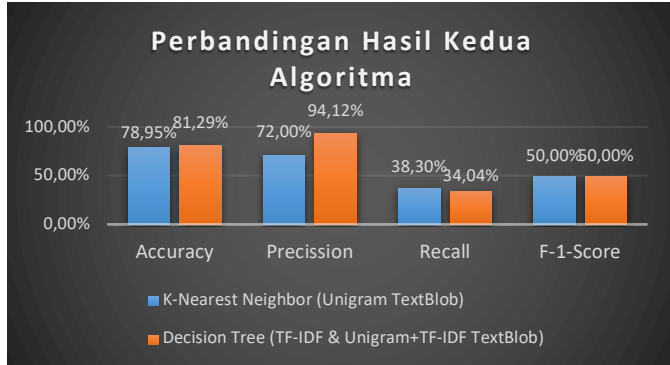
Perbandingan hasil pengujian dilakukan untuk mengetahui nilai akurasi yang lebih baik antara metode *K-Nearest Neighbor* dan *Decision Tree*. Tabel XXVII merupakan hasil perbandingan dari kedua metode yang digunakan.

TABEL XXVII
PERBANDINGAN HASIL PENGUJIAN METODE *K-NN* DAN *DECISION TREE*

Algoritma	Accuracy	Precision	Recall	F-1 Score
<i>K-Nearest Neighbor</i> (<i>Unigram TextBlob</i>)	78,95%	72,00%	38,30%	50,00%
<i>Decision Tree</i> (<i>TF-IDF & Unigram+TF-IDF TextBlob</i>)	81,29%	94,12%	34,04%	50,00%

Berdasarkan hasil perbandingan dari pengujian yang telah dilakukan, data labelling *textblob* memiliki nilai akurasi lebih baik dibandingkan data labelling *VADER*. Metode *K-Nearest*

Neighbor dengan fitur unigram memiliki tingkat akurasi yang tinggi. Nilai *accuracy* yang dihasilkan yaitu 78,95%, *precision* 72%, *recall* 38,30%, dan *f-1 score* 50%. Sedangkan metode *Decision Tree* memiliki nilai akurasi tertinggi dengan menggunakan fitur *TF-IDF & TF-IDF Unigram*. Nilai akurasi yang dihasilkan yaitu 81,29%, *precision* 94,12%, *recall* 34,04%, *f-1 score* 50%. Gbr. 16 merupakan visualisasi dari perbandingan hasil pengujian kedua metode yang digunakan.



Gbr. 16 Hasil Visualisasi Perbandingan Metode K-Nearest Neighbor (K-NN) dan Decision Tree

IV. KESIMPULAN

Berdasarkan hasil dari penelitian analisis sentimen yang telah dilakukan, kelas sentimen mengenai informasi pasca bencana alam di media sosial *twitter* dengan menggunakan metode *K-Nearest Neighbor (K-NN)* dan *Decision Tree* termasuk kelas sentimen negatif. Hasil tersebut diperoleh dari jumlah kelas sentimen yang dihasilkan dari data labelling *textblob* yaitu kelas sentimen negatif 1187 data dan sentimen positif 518 data. Sedangkan data labelling *VADER* menghasilkan kelas sentimen negatif yaitu 1076 data dan sentimen positif yaitu 629 data.

Hasil pengujian menunjukkan bahwa data labelling *textblob* memiliki nilai akurasi yang lebih baik dibandingkan dengan data labelling *VADER*. Metode *K-Nearest Neighbor (K-NN)* mempunyai akurasi tertinggi menggunakan fitur *unigram* dengan nilai *accuracy* sebesar 78,95%, nilai *precision* sebesar 72%, *recall* sebesar 38,30%, dan *f-1 score* sebesar 50%. Sedangkan metode *Decision Tree* menunjukkan nilai akurasi tertinggi ketika menggunakan fitur *TF-IDF* dan *TF-IDF Unigram*. Nilai *accuracy* yang dihasilkan yaitu sebesar 81,29%, nilai *precision* sebesar 94,12%, *recall* sebesar 34,04%, dan *f-1 score* sebesar 50%. Dari hasil akurasi yang diperoleh, menunjukkan bahwa metode *Decision Tree* mempunyai nilai akurasi yang lebih baik dibandingkan dengan metode *K-Nearest Neighbor (K-NN)*.

V. SARAN

Penelitian ini menghasilkan data yang tidak seimbang, sehingga penelitian selanjutnya dapat difokuskan atau memungkinkan pada penggunaan teknik *imbalance data*. Untuk penggunaan kamus pada proses *preprocessing* masih dibuat secara manual, untuk penelitian selanjutnya bisa dilakukan penambahan kata dasar secara otomatis. Selain itu,

penelitian lebih lanjut dapat dilakukan dengan menggunakan metode klasifikasi lain.

UCAPAN TERIMA KASIH

Alhamdulillah, puji syukur kepada Allah SWT yang selalu memberikan saya kesehatan dan kelancaran sehingga saya bisa menyelesaikan penelitian ini. Saya sangat berterima kasih kepada kedua orang tua saya yang selalu mendukung, memberikan kekuatan serta selalu ada untuk saya. Dan saya juga mengucapkan terima kasih yang sebesar-besarnya kepada pembimbing saya yang selalu memberikan bimbingan, mendorong saya, dan memberikan saran-saran hingga selesainya penelitian ini. Saya juga mengucapkan terima kasih kepada orang terdekat saya serta teman-teman yang memberikan dukungan dalam pembuatan penelitian ini.

REFERENSI

- [1] Antaranews.com. 2021. Indonesia sejak awal 2021. <https://www.antaranews.com/berita/1990236/372-bencana-alam-terjadi-di-wilayah-indonesia-sejak-awal-2021>
- [2] Liu, B. (2022). *Sentiment analysis and opinion mining*. Springer Nature.
- [3] Romadloni, N. T., Santoso, I., & Budilaksono, S. (2019). Perbandingan Metode Naive Bayes, K-NN Dan Decision Tree Terhadap Analisis Sentimen Transportasi Krl Commuter Line. *IKRA-ITH Informatika: Jurnal Komputer dan Informatika*, 3(2), 1-9.
- [4] Bayhaqy, A., Sfenrianto, S., Nainggolan, K., & Kaburuan, E. R. (2018, October). Sentiment analysis about E-commerce from tweets using decision tree, K-nearest neighbor, and naive bayes. In *2018 international conference on orange technologies (ICOT)* (pp. 1-6). IEEE.
- [5] Puspita, R., & Widodo, A. (2021). Perbandingan Metode K-NN, Decision Tree, dan Naive Bayes Terhadap Analisis Sentimen Pengguna Layanan BPJS. *J. Inform. Univ. Pamulang*, 5(4), 646.
- [6] Syarifuddin, M. (2020). Analisis sentimen opini publik terhadap efek PSBB pada twitter dengan algoritma decision tree, K-NN, dan naive bayes. *INTI Nusa Mandiri*, 15(1), 87-94.
- [7] Zumarniansyah, A., Pebrianto, R., Normah, N., & Gata, W. (2020). Twitter Sentiment Analysis of Post Natural Disasters Using Comparative Classification Algorithm Support Vector Machine and Naive Bayes. *Jurnal Pilar Nusa Mandiri*, 16(2), 169-174.
- [8] Mehta, U. R. M. I. T. A., & Verma, D. (2021). Sentiment Analysis of Facebook Using Textblob and Vader. *Journal of Innovative Engineering and Research (JIER)*, 4(1), 10-4.
- [9] Illia, F., Eugenia, M. P., & Rutba, S. A. (2021). Sentiment analysis on pedulilindungi application using textblob and vader library. In *Proceedings of The International Conference on Data Science and Official Statistics* (Vol. 2021, No. 1, pp. 278-288).
- [10] Indarbensyah, P. P. E., & Rochmawati, N. (2021). Penerapan N-Gram menggunakan Algoritma Random Forest dan Naive Bayes Classifier pada Analisis Sentimen Kebijakan PPKM 2021. *J. Informatics Comput. Sci*, 2(04), 235-244.
- [11] Fitriyani, F., & Arifin, T. (2020). Penerapan Word N-Gram Untuk Sentiment Analysis Review Menggunakan Metode Support Vector Machine (Studi Kasus: Aplikasi Sambara). *Sistemasi: Jurnal Sistem Informasi*, 9(3), 610-621.
- [12] Risnantoyo, R., Nugroho, A., & Mandara, K. (2020). Sentiment analysis on corona virus pandemic using machine learning algorithm. *Journal of Informatics and Telecommunication Engineering*, 4(1), 86-96
- [13] Kurniasari, R., & Fatmawati, A. (2019). Penerapan algoritma C4. 5 untuk penjurusan siswa sekolah menengah atas. *Komputa: Jurnal Ilmiah Komputer Dan Informatika*, 8(1), 19-27.