

ANALISIS SENTIMEN REVIEW APLIKASI *CRYPTOCURRENCY* MENGUNAKAN ALGORITMA *MAXIMUM ENTROPY* DENGAN METODE PEMBOBOTAN TF, TF-IDF DAN *BINARY*

Fadhilla Atansa Tamardina¹, Hasbi Yasin^{2*}, Dwi Ispriyanti³

^{1,2,3}Departemen Statistika, Fakultas Sains dan Matematika, Universitas Diponegoro

*e-mail hasbiyasin@live.undip.ac.id

ABSTRACT

Pandemi COVID-19 yang belum berhenti menyebabkan kondisi ekonomi Indonesia kian memburuk. Masyarakat yang terkena dampak pemotongan upah akibat pandemi harus mencari cara untuk mendapatkan pendapatan pasif. Salah satu cara untuk mendapatkan hal tersebut adalah berinvestasi. *Cryptocurrency* adalah salah satu instrumen investasi berbasis aplikasi yang memiliki *return* tinggi. Aplikasi Pintu adalah aplikasi pertama yang menyediakan fasilitas *mobile apps* pada penggunaannya. Aplikasi yang dirilis pada tahun 2020 ini sudah memiliki banyak ulasan yang diberikan oleh penggunaannya. Ulasan ini dibutuhkan untuk mengetahui apakah ulasan yang diberikan bersifat positif atau negatif. Analisis sentimen pada aplikasi Pintu dipilih untuk melihat sentimen pengguna yang akan dibagi menjadi dua kelas sentimen yaitu positif dan negatif. Klasifikasi dilakukan dengan algoritma *Maximum Entropy* dengan perbandingan metode pembobotan kata *Term Frequency* (TF), *Term Frequency-Inverse Document Frequency* (TF-IDF) dan *Binary*. Model klasifikasi terbaik dilihat berdasarkan nilai akurasi yang dievaluasi dengan *5-Fold Cross Validation*. Hasil klasifikasi model *Maximum Entropy* dengan *Binary* memiliki tingkat akurasi sebesar 83,21% sedangkan hasil klasifikasi model *Maximum Entropy* dengan *Term Frequency* hanya sebesar 83,01% dan model *Maximum Entropy* dengan *Term Frequency-Inverse Document Frequency* hanya sebesar 83,20%. Hal ini menunjukkan bahwa tidak terdapat perbedaan yang signifikan pada model algoritma *Maximum Entropy* dengan metode pembobotan kata *Term Frequency* (TF), *Term Frequency-Inverse Document Frequency* (TF-IDF) dan *Binary*.

Keywords: *Cryptocurrency*, *Binary*, *Term Frequency*, *Term Frequency-Inverse Document Frequency*, *Maximum Entropy*

1. PENDAHULUAN

Pada awal Maret 2020, Pemerintah Indonesia resmi menerapkan *social distancing* dan *physical distancing*. Akibatnya, masyarakat cenderung memilih untuk aktif dalam dunia maya. Maraknya penggunaan media sosial di Indonesia menunjukkan hasil produktivitas yang lebih baik. Hal tersebut terbukti dari data rata-rata bulanan untuk waktu penggunaan aplikasi *mobile non-game* di Indonesia pada kuartal ke-2 naik 25 persen menurut *App Annie*

Berdasarkan survei yang dilakukan oleh Jobstreet, 43% pekerja di Indonesia mengalami pemotongan gaji akibat pandemi. Masyarakat pun lebih tertarik untuk berinvestasi dengan aplikasi untuk mendapatkan pendapatan pasif dengan *cryptocurrency* yang memiliki *return* tinggi dalam setahun. Penggunaannya pun sangat aman karena adanya teknik enkripsi dengan mengacak info untuk membuat aktivitas menjadi rahasia dan sulit diakses oleh pihak luar. Salah satu aplikasi *cryptocurrency* yang diminati untuk diunduh adalah Pintu.

Penelitian ini difokuskan pada analisis sentimen yang mengacu pada ulasan aplikasi Pintu dengan metode pembobotan kata *Term Frequency* (TF), *Term Frequency-Inverse Document Frequency* (TF-IDF) dan *Binary*. Tujuannya adalah untuk mengetahui perbedaan yang signifikan dari ketiga model kemudian memberi rekomendasi serta saran kepada pengembang aplikasi Pintu.

2. TINJAUAN PUSTAKA

2.1. *Cryptocurrency*

Cryptocurrency adalah mata uang virtual yang dapat digunakan sebagai alternatif transaksi dengan mekanisme melalui dukungan jaringan internet yang dilindungi dengan sistem sandi komputer yang rumit secara aman atau sering disebut teknologi *blockchain*.

2.1.1. *Google Play Store*

Google Play Store atau dikenal sebelumnya dengan *Android Market* adalah layanan distribusi digital berbentuk toko aplikasi resmi untuk *Android* yang dioperasikan dan dikembangkan oleh *Google*.

2.1.2. *Pintu*

Pintu adalah perusahaan teknologi *blockchain* terkemuka di Indonesia. (Pintu, 2020). *Pintu* merupakan aplikasi *mobile cryptocurrency* pertama di Indonesia yang mengedepankan kemudahan untuk jual atau beli aset *crypto* melalui *smartphone*. *Pintu* menyediakan infrastruktur yang memungkinkan pengguna untuk *trading*, mengirim, dan menyimpan aset *crypto*.

2.1.3. *Online Review*

Online review dari pelanggan diartikan sebagai hasil evaluasi produk yang diunduh dalam situs perusahaan atau situs pihak ketiga (Mudambi dan Schuff, 2010). Pengguna aplikasi di *Google Play Store* dapat memberikan ulasan yang bersifat public dengan menulis ulasan kepuasan atau keluhan sesuai pengalaman menggunakan aplikasi yang diunduh di *Google Play Store*.

2.2. Analisis Sentimen

Menurut (Liu, 2012), analisis sentimen atau *opinion mining* mengacu pada bidang yang luas dari pengolahan bahasa alami, komputasi linguistik dan *text mining* yang memiliki tujuan menganalisa pendapat, sentimen, evaluasi, sikap, penilaian dan emosi seseorang apakah pembicara atau penulis berkenan dengan suatu topik, produk, layanan, organisasi, individu, ataupun kegiatan tertentu. Sentimen yang didapatkan nantinya akan diklasifikasikan dalam bentuk positif, negatif atau netral.

2.3. *Text Mining*

Text mining adalah satu teknik yang dapat digunakan untuk melakukan klasifikasi dalam untuk menemukan pola yang menarik dari sekumpulan data tekstual yang berjumlah besar. Karakteristik data tekstual umumnya memiliki dimensi tinggi, terdapat *noise* dan memiliki struktur yang tidak baik. Untuk mengatasinya, proses *text mining* dibagi menjadi *text preprocessing* dan *feature selection* (Feldman & Sanger, 2007).

2.4. *Text Preprocessing*

Text preprocessing adalah proses mempersiapkan teks dokumen atau *dataset* mentah yang sebelumnya tidak terstruktur atau sembarang menjadi data yang terstruktur. Pada penelitian ini menggunakan *spelling normalization*, *case folding*, *tokenizing*, *filtering*, dan *stemming*.

2.5. Pelabelan Kata

Penelitian ini menggunakan *sentiment scoring* untuk melabelkan kata. *Sentiment scoring* merupakan teknik yang digunakan untuk melabelkan suatu pernyataan yang digolongkan menjadi sentimen positif atau negatif.

2.6. Term Weighting

Term Weighting atau pembobotan kata adalah metode untuk memberikan nilai atau bobot pada masing - masing *term*. Pada penelitian ini, peneliti menggunakan perbandingan metode pembobotan kata dengan menggunakan *Term Frequency* (TF), *Term Frequency – Inverse Document* (TF-IDF) dan *Binary*.

2.6.1. Term Frequency (TF)

Term-Frequency atau TF murni merupakan metode yang paling sederhana. Metode ini didasarkan pada jumlah kemunculan *term* atau kata dalam dokumen. Contohnya jika muncul lima kali maka kata tersebut bernilai lima.

$$W_{i,j} = tf_{i,j} \quad (1)$$

Keterangan :

$W_{i,j}$: Pembobotan TF untuk *term* ke – i pada dokumen ke – j

tf_{ij} : Jumlah kemunculan *term* t_j dalam dokumen d_i

2.6.2. Term Frequency – Inverse Document Frequency (TF-IDF)

Metode TF-IDF menghitung nilai dari masing-masing kata di dalam dokumen menggunakan frekuensi kata (*term*) tersebut muncul. Semakin besar jumlah *term* yang muncul (TF tinggi) maka semakin besar bobot dokumen.

$$W_{i,j} = \frac{n_{i,j}}{\sum_k n_{k,j}} \cdot \log_2 \frac{D}{d_i} \quad (2)$$

Keterangan :

$W_{i,j}$: Pembobotan TF-IDF untuk *term* ke – i pada dokumen ke – j

$n_{i,j}$: Banyaknya kemunculan *term* ke – i pada dokumen ke – j

$\sum_k n_{k,j}$: Jumlah kemunculan seluruh *term* pada dokumen ke – j

D : Banyaknya dokumen yang dibangkitkan

d_i : Banyaknya dokumen yang mengandung *term* ke – i

2.6.3. Binary

Metode pembobotan kata binary adalah metode yang hanya memperhatikan ada tidaknya kata atau *term* pada sebuah dokumen, jika ada diberi nilai satu (1) jika tidak ada diberi nilai nol (0).

$$W_{i,j} = \begin{cases} 1, & \text{jika dokumen ke – j mengandung term ke – i} \\ 0, & \text{jika dokumen ke – j tidak mengandung term ke – i} \end{cases} \quad (3)$$

Keterangan :

$W_{i,j}$: Pembobotan *binary* untuk *term* ke – i pada dokumen ke – j

2.7. Maximum Entropy

Maximum entropy adalah sebuah metode klasifikasi yang menggunakan nilai *entropy* untuk mengklasifikasikan suatu data. *Entropy* digunakan untuk mengukur tingkat heterogenitas atau keberagaman terhadap suatu kumpulan data. Secara definisi metode ini

digunakan untuk mencari probabilitas distribusi yang mempunyai nilai *entropy* tinggi. Probabilitas yang dimaksud ialah hasil prediksi dari suatu teks atau kalimat yang mengandung informasi. Fungsi umum *entropy* adalah sebagai berikut:

$$Entropy(X) = -\sum_{i=1}^n P(x_i) \log_2 P(x_i) \quad (4)$$

Dengan n adalah jumlah nilai yang ada pada atribut (jumlah kelas klasifikasi), sedangkan $P(x_i)$ menyatakan probabilitas sampel untuk kelas i . Pada klasifikasi teks, hasil adalah anggota dari suatu himpunan y dan kondisi yang mempengaruhi nilai hasil tersebut dinamakan sebagai konteks, yang mana konteks merupakan anggota dari himpunan x . Himpunan x adalah fitur-fitur yang dikombinasikan. *Output* yang didapatkan dengan menggunakan metode *maximum entropy* adalah probabilitas himpunan y terhadap x (dipresentasikan ke dalam fungsi $f(x,y)$). Berikut ialah fungsi tersebut:

$$f(x, y) = \begin{cases} 1, & \text{jika } y=y \text{ dan } x=\text{benar} \\ 0, & \text{lainnya} \end{cases} \quad (5)$$

Probabilitas bersyarat (*conditional probability*) atau suatu keadaan y terhadap x dapat dilihat pada persamaan berikut:

$$p(y|x) = \frac{1}{Z_i(x)} \exp(\sum_i \lambda_i f_i(x, y)) \quad (6)$$

Dengan $\exp(\sum_i \lambda_i f_i(x, y))$ adalah nilai kejadian spesifik dalam suatu dokumen terhadap kelas, sedangkan nilai Z atau nilai normalisasi dari setiap kata dengan rumus sebagai berikut:

$$Z_\alpha(x) = \sum_y \exp(\sum_i \lambda_i f_i(x, y)) \quad (7)$$

2.8. K-Fold Cross Validation

K-Fold Cross Validation adalah salah satu metode *cross validation* yang digunakan untuk menghitung akurasi prediksi suatu sistem. Data dibagi menjadi k segmen yang memiliki rasio yang sama atau hampir sama. Pelatihan terhadap data dan validasi sebanyak k kali dengan setiap percobaan mengambil satu segmen berbeda sebagai data tes atau validasi dan $k-1$ segmen lainnya sebagai data latih untuk diambil rata-rata dari hasil tiap iterasi (Refaeilzadeh, et al., 2009). Rata-rata akurasi keseluruhan iterasi dijadikan ukuran dalam mengevaluasi kinerja klasifikasi, yang mana dihitung dengan rumus berikut:

$$\bar{x} = \frac{\sum x}{n} \quad (8)$$

dengan n adalah banyaknya nilai dalam sampel dan $\sum x$ adalah jumlah nilai x dalam sampel.

2.9. Evaluasi Model Klasifikasi

Pada kinerja klasifikasi terdapat evaluasi untuk empat kemungkinan yang bisa terjadi dari suatu data. Jika data positif dan diprediksi positif maka akan dihitung sebagai *true positive* dan jika data positif diprediksi negatif maka akan dihitung sebagai *false negative*. Pada data negatif jika diprediksi negatif akan dihitung sebagai *true negative* dan jika diprediksi positif maka akan dihitung sebagai *false positive* (Fawcett, 2006). Hasil kinerja klasifikasi biner dapat dipresentasikan dalam *confusion matrix*.

Tabel 1. *Confusion Matrix*.

Penelitian ini menggunakan evaluasi kinerja klasifikasi model dengan nilai akurasi yang diperoleh dengan menggunakan persamaan berikut:

		Predicted	
		Positive	Negative
Actual	Positive	True Positive (TP)	False Negative (FN)
	Negative	False Positive (FP)	True Negative (TN)

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

2.10. Word Cloud

Word Cloud merupakan pendekatan yang dapat menjelaskan pertanyaan penelitian dengan sangat cepat dan mudah. *Word Cloud* dapat menampilkan kata yang paling sering muncul atau paling sering digunakan pada suatu *web* ataupun teks. Kata yang paling sering muncul akan memiliki ukuran yang lebih besar dari kata yang lain.

2.11. Diagram Fishbone

Diagram *Fishbone* dikenal juga sebagai diagram Sebab-Akibat. Konsep diagram *fishbone* secara umum adalah dengan meletakkan permasalahan mendasar pada bagian kepala atau bagian paling kanan dari diagram kerangka tulang ikan. Diagram ini berguna untuk memperlihatkan faktor-faktor utama yang berpengaruh pada kualitas dan mempunyai akibat pada masalah yang dipelajari (Haizer, J. & Barry, R., 2008).

3. METODE PENELITIAN

3.1. Jenis dan Sumber Data

Jenis data yang digunakan merupakan data primer berupa data kualitatif. Data yang digunakan adalah ulasan dari pengguna aplikasi Pintu. *Web scraping* dilakukan pada tanggal 30 Mei 2021 dengan *Data Miner*. Data hasil *web scraping* diperoleh sebanyak 1184 ulasan yang kemudian dieliminasi menjadi sebanyak 500 ulasan untuk diteliti. Sampel ulasan tersebut diambil dari tanggal 4 Februari 2020 – 5 Februari 2021 yang akan digunakan untuk mengetahui kinerja aplikasi Pintu dalam setahun.

3.2. Langkah-Langkah Analisis Data

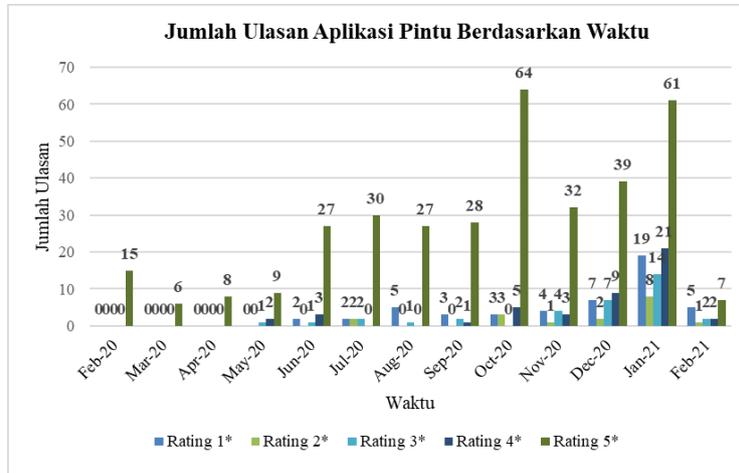
Metode yang digunakan dalam penelitian ini adalah *Maximum Entropy*. Analisis data pada penelitian ini dilakukan dengan bantuan *software* RStudio dan Microsoft Excel 2016. Adapun langkah-langkah analisis yang dilakukan adalah sebagai berikut:

1. *Web Scraping*
2. *Data Preprocessing*,
3. Pelabelan data
4. Pembobotan kata dengan TF, TF-IDF dan *Binary*
5. *Feature Selection (Stopwords Removal, Stemming, dan Tokenizing)*
6. Membangun model klasifikasi dan melakukan pengujian model klasifikasi
7. Mengevaluasi performansi model
8. Interpretasi hasil ke dalam bentuk visual menggunakan *word cloud* dan diagram *fishbone*.

4. HASIL DAN PEMBAHASAN

4.1. Deskripsi Data Penelitian

Data ulasan yang akan dianalisis diambil dari beberapa kriteria yaitu, jumlah ulasan yang masuk berdasarkan urutan waktu, *rating* aplikasi dan perbandingan jumlah ulasan positif dan ulasan negatif. Berikut ini merupakan jumlah ulasan aplikasi Pintu berdasarkan waktu.



Gambar 1. Histogram Ulasan Aplikasi Pintu Berdasarkan Waktu.

Dari grafik ini dapat dilihat bahwa dalam setahun aplikasi Pintu mengalami penambahan jumlah ulasan dari pengguna. Hal tersebut membuktikan bahwa tingkat kepercayaan pengguna dalam berinvestasi *cryptocurrency* di aplikasi Pintu bertambah sehingga pengguna berani untuk memberi ulasan.



Gambar 2. Bar Chart Rating Pengguna Aplikasi Pintu.

Diketahui bahwa terdapat 358 pengguna paling banyak memberikan *rating* “Sangat Suka”. Hal ini menunjukkan bahwa aplikasi Pintu sudah cukup mampu memuaskan pengguna dalam waktu hampir setahun dari waktu rilis aplikasi.

4.2. Text Preprocessing

Proses ini membersihkan dan mentransformasi data agar siap untuk diolah. Penelitian ini menggunakan *case folding*, *remove number*, *remove punctuation*, *remove emoticon*, *strip whitespace* dan normalisasi kata.

4.3. Pelabelan Kata

Pelabelan menggunakan teknik *sentiment scoring*, mendapatkan hasil bahwa kelas sentimen positif lebih dominan dibandingkan kelas sentimen negatif. Jumlah ulasan yang masuk ke dalam kelas positif sebanyak 390 ulasan dan ulasan yang masuk ke dalam kelas negatif sebanyak 110 ulasan. Pelabelan menggunakan teknik *sentiment scoring* masih menimbulkan kesalahan sebanyak 14 atau 2,8% dari 500 ulasan. Kesalahan ini disebabkan karena skor akhir dari masing-masing ulasan yang dihitung oleh program komputasi berbeda dengan penilaian yang diputuskan oleh manusia. Hal ini memang seringkali terjadi karena sentimen merupakan hal yang bersifat subjektif. Kesalahan dalam pelabelan dengan *sentiment scoring* tersebut diganti dengan pelabelan manual untuk mendapatkan label yang benar pada seluruh ulasan sehingga dapat memberikan performa yang optimal. Setelah dilakukan perbaikan, jumlah ulasan positif menjadi sebanyak 376 dan ulasan negatif sebanyak 651.

4.4. Feature Selection

Pada penelitian ini, *feature selection* dilakukan dengan melakukan *stopwords removal*, *tokenizing* dan *stemming*. Setelah melalui *stopwords removal*, jumlah kata pada seluruh dokumen adalah sebanyak 6338 *term* yang sebelumnya berjumlah sebanyak 2330 *term*. Proses *tokenizing* digunakan untuk memisahkan kata per kata tiap ulasan dan *stemming* dilakukan untuk mengubah kata-kata yang berimbuhan menjadi kata dasar.

4.5. Pembobotan Kata

4.5.1. Term Frequency (TF)

Pembobotan kata dibutuhkan untuk mengubah *term* menjadi bilangan yang dapat dihitung dan diolah. Tabel 2 merupakan hasil pembobotan kata menggunakan TF.

Tabel 2. Contoh Hasil Pembobotan TF pada Beberapa *Term*.

<i>Term</i>	Dok 1	Dok 2	Dok 3	Dok 4	⋮	Dok 500	Jumlah
bagus	1	1	0	1	⋮	0	156
bisa	0	0	0	0	⋮	0	66
tambah	0	0	0	0	⋮	1	13

4.5.2. Term Frequency – Inverse Document Frequency (TF-IDF)

Pembobotan kata dibutuhkan untuk mengubah *term* menjadi bilangan yang dapat dihitung dan diolah. Tabel 3 merupakan hasil pembobotan kata menggunakan TF-IDF.

Tabel 3. Contoh Hasil Pembobotan TF-IDF pada Beberapa *Term*.

Dokumen	TF-IDF						
	bagus	bisa	guna	masalah	masuk	susah	tambah
Dokumen 1	0,45913	0	0,82334	0	0	0	0
Dokumen 2	0,3673	0	1,31734	0,87616	0	0	0

⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
Dokumen 500	0	0	0	0	0	3,32193	0

4.5.3. Binary

Pembobotan kata dibutuhkan untuk mengubah *term* menjadi bilangan yang dapat dihitung dan diolah. Tabel 4 merupakan hasil pembobotan kata menggunakan *Binary*.

Tabel 4. Contoh Hasil Pembobotan *Binary* pada Beberapa *Term*.

<i>Term</i>	Dok 1	Dok 2	Dok 3	Dok 4	⋮	Dok 500	Jumlah
bagus	1	1	0	1	⋮	0	140
bisa	0	0	0	0	⋮	0	55
tambah	0	0	0	0	⋮	1	12

4.6. Klasifikasi Sentimen

4.6.1 Data Latih dan Data Uji

Rasio data latih dan data uji yang digunakan dalam penelitian ini adalah 80% : 20%. Tabel 5 merupakan perbandingan proporsi data latih dan data uji.

Tabel 5. Proporsi Data Latih dan Data Uji.

Klasifikasi	Data Latih (80%)	Data Uji (20%)	Jumlah
Positif	300,8 ≈ 301	75,2 ≈ 75	376
Negatif	99,2 ≈ 99	24,8 ≈ 25	124
Jumlah	400	100	500

4.6.2 Maximum Entropy

Evaluasi performansi yang digunakan adalah *confusion matrix* dengan *accuracy* sebagai parameter. Tabel 6 merupakan hasil dari nilai *accuracy* model *Maximum Entropy* dengan TF, TF-IDF dan *Binary*.

Tabel 6. Rata – Rata Tingkat *Accuracy* Model.

	Maximum Entropy		
	TF	TF-IDF	<i>Binary</i>
<i>Accuracy</i>	83,01	83,20	83,21
<i>Sensitivity</i>	73,40	62,13	71,77
<i>Specifity</i>	86,17	90,15	86,99

4.7. Word Cloud

Visualisasi *word cloud* menggunakan *software* RStudio. Semakin besar ukuran kata maka semakin besar pula frekuensi kemunculan kata tersebut pada suatu dokumen.

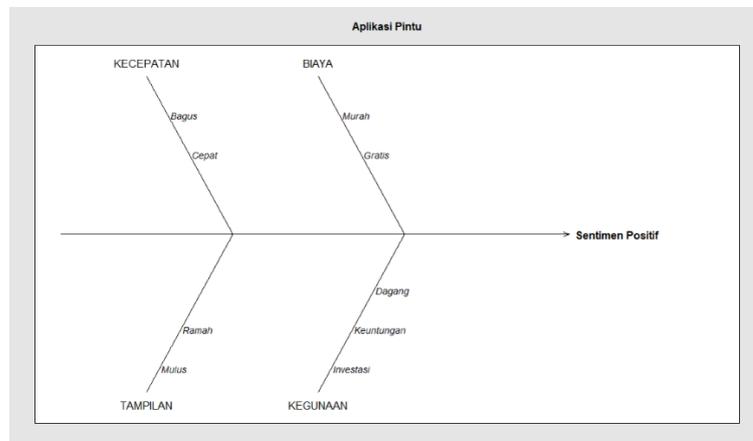


Gambar 3. *Word Cloud* Sentimen Positif dan Sentimen Negatif.

Gambar 3 menunjukkan bahwa kata dalam ulasan aplikasi Pintu pada kelas sentimen positif yang sering muncul adalah kata “bagus”. Kata tersebut menggambarkan bahwa pengguna aplikasi Pintu telah mendapatkan pengalaman yang bagus saat memakai aplikasi Pintu. Kata yang sering muncul pada sentimen negatif adalah “masuk” dan “bisa”. Kata “bisa” adalah kata yang bersifat negatif yang disampaikan oleh pengguna aplikasi Pintu dikarenakan banyak pengguna yang tidak bisa masuk ke dalam aplikasi.

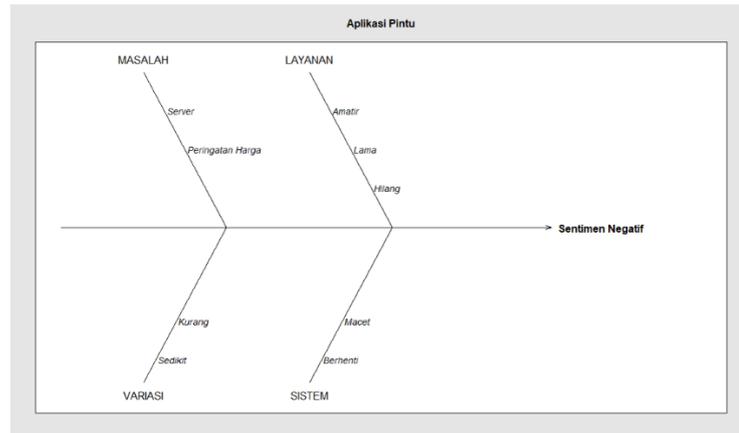
4.8. Diagram *Fishbone*

Diagram *fishbone* atau diagram sebab – akibat pada penelitian ini dibagi menjadi dua akibat yaitu sentimen positif dan sentimen negatif. Dari dua akibat tersebut dibagi menjadi beberapa penyebab permasalahan yang dibagi secara manual oleh peneliti dengan melihat hasil pelabelan.



Gambar 4. Diagram *Fishbone* Sentimen Positif.

Gambar 5 menunjukkan sirip ikan atau penyebab dari sentimen positif adalah tampilan, kegunaan, biaya dan kecepatan. Misal sirip “tampilan” memiliki duri yaitu “mulus” dan “ramah” yang dapat diartikan bahwa tampilan pada aplikasi Pintu sangat mulus dan ramah pengguna sehingga pengguna memberikan ulasan yang bersifat positif.



Gambar 5. Diagram *Fishbone* Sentimen Negatif.

Gambar 6 menunjukkan sirip ikan atau penyebab dari sentimen negatif adalah masalah, variasi, sistem dan layanan. Misal sirip “variasi” memiliki duri yaitu “sedikit” dan “kurang” yang dapat diartikan bahwa variasi koin *cryptocurrency* pada aplikasi Pintu masih sedikit dan kurang variatif sehingga pengguna memberikan ulasan yang bersifat negatif.

5. KESIMPULAN

Pengguna aplikasi Pintu cenderung menuliskan ulasan positif dalam aplikasi Pintu berdasarkan pada pelabelan yang telah dilakukan. Pelabelan menggunakan teknik *sentiment scoring* masih menimbulkan kesalahan diakibatkan skor yang dihitung oleh program tidak sesuai dengan penilaian yang diputuskan oleh manusia. Hal ini disebabkan penentuan kelas sentimen yang melibatkan persepsi manusia. Klasifikasi menggunakan *Maximum Entropy* dengan metode pembobotan kata TF menghasilkan performa dengan tingkat akurasi sebesar 83,01%, sementara *Maximum Entropy* dengan metode pembobotan kata TF-IDF menghasilkan performa dengan tingkat akurasi 83,20% dan *Maximum Entropy* dengan metode pembobotan kata *Binary* menghasilkan performa dengan tingkat akurasi 83,21%. Sehingga, tidak terdapat perbedaan yang signifikan dari hasil tingkat akurasi untuk ketiga model tersebut.

DAFTAR PUSTAKA

- Fawcett, T., 2006. An Introduction to ROC Analysis. *Pattern Recognition Letters*, Volume 27(8), pp. 861-874.
- Feldman, R. & Sanger, J., 2007. *The Text Mining Handbook: Advanced approaches in Analyzing Unstructured Data*. New York: Cambridge University Press.
- Haizer, J. & Barry, R., 2008. *Operation Management*. Jakarta: Salemba Empat.
- Liu, B., 2012. *Sentiment Analysis and Opinion Mining*. Rafael: Morgan & Claypool Publisher.
- Pintu. 2020. Kami Adalah Pintu. <https://pintu.co.id/about>. Diakses: 12 Februari 2021.
- Refaeilzadeh, P., Tang, L. & Liu, H., 2009. *Encyclopedia of Database Systems*. New York: Springer.
- Mudambi, S. M. dan Schuff, D. (2010). *What Makes A Helpful Online Review? A Study of Customer Reviewa on Amazon.com*. *Mis Quarterly*, Vol. 34, No. 1, Hal. 185-200.