



Analisis Sentimen terhadap Kalimat Finansial pada FiQA dan *The Financial PhraseBank*

Maximilianus Noel Brilianto, Yuliana Susanti, Etik Zukhronah

Program Studi Statistika, Universitas Sebelas Maret, Surakarta, Indonesia

* Corresponding Author. E-mail: yulianasusanti@staff.uns.ac.id

ARTICLE INFO

Article History:

Received: 01-Apr. 2023

Revised: 05-Jun. 2023

Accepted: 12-Aug. 2023

Keywords:

Analisis sentiment,
algoritma *naïve bayes*,
algoritma *decision tree*,
algoritma *K-Nearest Neighbor*.

ABSTRACT

Analisis sentimen atau bisa disebut juga *opinion mining* merupakan salah satu tugas utama dari *natural language processing* (NLP) yang merupakan studi komputasi yang mempelajari tentang pendapat seseorang terhadap suatu topik bahasan atau entitas. Analisis dilakukan dengan algoritma *machine learning* (pembelajaran mesin) *naïve bayes*, *decision tree*, dan *K-nearest neighbor* dengan membagi sentimen ke dalam dua kategori sentimen yaitu sentimen positif dan sentimen negatif. Data analisis diambil dari *financial opinion mining and question answering* (FiQA) dan *The Financial PhraseBank* yang terdiri dari 4.840 kalimat yang dipilih dari berbagai berita keuangan dan dianotasi oleh 16 annotator berbeda yang berpengalaman dalam domain finansial. Penelitian ini ditujukan untuk mendapatkan hasil analisis sentimen dengan algoritma terbaik melalui perbandingan performa algoritma *machine learning naïve bayes*, *decision tree*, dan *K-nearest neighbor* terhadap kalimat finansial yang disajikan oleh FiQA dan *The Financial PhraseBank*. Berdasarkan analisis, didapatkan hasil performa dari masing-masing algoritma dengan nilai akurasi algoritma *naïve bayes* sebesar 78,45%; algoritma *decision tree* dengan nilai akurasi sebesar 77,72%; algoritma *K-nearest neighbor* ($k=3$) dengan nilai akurasi sebesar 41,25%; dan *K-nearest neighbor* ($k=5$) dengan nilai akurasi sebesar 37,38%. Analisis sentimen dengan algoritma *naïve bayes* memiliki performa paling baik dengan nilai akurasi paling tinggi.

Sentiment analysis or can also be called opinion mining is one of the main tasks of natural language processing (NLP) which is a computational study that studies a person's opinion on a topic or entity. The analysis was performed with machine learning algorithms naïve bayes, decision tree, and K-nearest neighbor by dividing sentiment into two categories of sentiment namely positive sentiment and negative sentiment. The analysis data was taken from financial opinion mining and question answering (FiQA) and The Financial PhraseBank which consisted of 4,840 sentences selected from various financial news and annotated by 16 different annotators experienced in the financial domain. This research is aimed at obtaining sentiment analysis results with the best algorithms through comparison of the performance of naïve bayes, decision tree, and K-nearest neighbor machine learning algorithms against financial sentences presented by FiQA and The Financial PhraseBank. Based on the analysis, the performance results of each algorithm were obtained with the accuracy value of the naïve bayes algorithm of 78.45%; decision tree algorithm with an accuracy value of 77.72%; K-nearest neighbor algorithm ($k=3$) with an accuracy value of 41.25%; and K-nearest neighbor ($k=5$) with an accuracy value of 37.38%. Sentiment analysis with the naïve bayes algorithm ($K=5$) performs best with the highest accuracy values.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-nc-sa/4.0/) license



How to Cite:

Brilianto, M. N., Susanti, Y., & Zukhronah, E. (2023). Analisis sentimen terhadap kalimat finansial pada FiQA dan the financial PhraseBank. *Pythagoras: Jurnal Matematika dan Pendidikan Matematika*, 18(1), 48-55. <https://doi.org/10.21831/pythagoras.v18i1.59760>

<https://doi.org/10.21831/pythagoras.v18i1.59760>

PENDAHULUAN

Analisis sentimen atau bisa disebut juga *opinion mining* merupakan studi komputasi yang mempelajari tentang pendapat seseorang terhadap suatu topik bahasan atau entitas. Topik bahasan dapat mewakili suatu individu, produk, dan/atau suatu pihak. Analisis sentimen berkaitan erat dengan jejaring sosial yang dimana hal ini

sejalan dengan berkembangnya jejaring sosial membuka peluang selebar-lebarnya bagi setiap individu untuk menyampaikan pendapatnya terhadap suatu topik bahasan. Ulasan atau penilaian seseorang di media sosial terhadap pihak yang terlibat atau disebutkan menjadi faktor kunci dalam pengambilan keputusan sebagai bentuk evaluasi kinerja dan kepuasan pelanggan. Dengan kata lain analisis sentimen dapat menunjukkan bahwa prediksi sentimen dari ulasan atau penilaian tertentu yang terdapat pada jejaring sosial dapat meningkatkan potensi keuntungan. Sentimen analisis cenderung merujuk pada subjektivitas analisis, *opinion mining*, dan ekstrasi penilaian yang berhubungan dengan komputasi afeksi (pengenalan komputer dan ekspresi emosi) (Pang dan Lee, 2008). Analisis sentimen mempelajari lebih dalam mengenai elemen subjektivitas sebagai "*linguistic expressions of private states in context*" (Wiebe et al., 2014). Ekspresi disini dapat berupa kata-kata, frase, ataupun kalimat. Sentimen analisis yang merupakan tugas dari *natural language processing* (NLP) yang merupakan proses untuk mendapatkan sebuah informasi pada sebuah kalimat opini dengan melewati proses pemahaman, ekstrasi, dan proses data teks (Muhammad et al., 2019). Analisis sentimen dapat dilakukan dengan mengklasifikasikan tipe ulasan kedalam dua kategori yaitu sentimen positif dan sentimen negatif dengan bantuan pada *machine learning* (pembelajaran mesin).

Machine learning atau pembelajaran mesin adalah cabang algoritma komputasi yang dirancang untuk meniru kecerdasan manusia dengan mempelajari data dan lingkungan sekitarnya (El Naqa dan Murphy, 2015). *Machine learning* adalah program yang dirancang sedemikian rupa sehingga dapat mempelajari berbagai hal secara mandiri dan berulang (Institute, 2018). Teknik klasifikasi *machine learning* berupa *naïve bayes*, *decision tree*, dan *K-nearest neighbor*. Pada teknik klasifikasi *machine learning* di atas dapat diketahui bahwa *naïve bayes* digunakan untuk menghitung probabilitas dengan waktu komputasi yang pendek pada data latih dengan performa yang baik (Jadhav dan Channe, 2016). Selain itu, penggunaan algoritma *naïve bayes* yang mudah (dalam interpretasi model) dan tingkat efisiensi yang baik, dipandang sebagai keunggulan dibanding algoritma atau teknik lainnya dalam *machine learning* (Ahmad et al., 2017; Singh & Husain, 2014). *Decision tree* dan *K-nearest neighbors* (KNN) merupakan algoritma *supervised learning* dengan pengambilan keputusan menggunakan model seperti pohon dan data yang baru masuk tergantung dengan nilai yang paling banyak pada "tetangga" nya. Kelebihan dari KNN sendiri yaitu melatih data latih secara cepat, mudah dipahami, dan diimplementasikan baik pada data latih ataupun data yang memiliki *noisy* (Jadhav dan Channe, 2016). Ketiga teknik klasifikasi tersebut dapat digunakan dalam proses analisis sentimen *financial statement* yang terdapat pada FiQA dan *The Financial PhraseBank*.

Financial opinion mining and question answering (FiQA) merupakan sebuah tantangan terbuka pada tahun 2018 yang bertujuan untuk melakukan investasi dalam pengembangan analisis *natural language processing* (NLP) di bidang finansial yang terus berkembang dari masa ke masa. Target dari tantangan ini berupa interpretasi dari data set finansial menggunakan tugas analisis sentimen berbasis aspek *question and answer* (QA) (Maia et al., 2018). *The Financial PhraseBank* adalah kumpulan data standar untuk klasifikasi sentimen yang terdiri dari 4.840 kalimat yang dipilih dari berita keuangan dan dianotasi untuk sentimen positif, negatif, dan netral oleh 16 annotator berbeda yang berpengalaman dalam domain finansial (Malo et al., 2013).

Terdapat penelitian sebelumnya yang telah dilakukan dan dipublikasikan mengenai perbandingan metode KNN, *decision tree*, dan *naïve bayes* terhadap analisis sentimen pengguna layanan BPJS yang menyatakan bahwa metode KNN, *decision tree*, dan *naïve bayes* dapat digunakan dalam bidang *data mining* dengan metode *decision tree* adalah metode yang tingkat akurasi lebih tinggi dibandingkan kedua metode lainnya (Puspita, 2020). Pada penelitian penerapan *naïve bayes classifier*, *K-nearest neighbor* (KNN) dan *decision tree* untuk menganalisis sentimen pada interaksi netizen dan pemerintah menunjukkan bahwa algoritma *naïve bayes* memiliki performa paling baik dibandingkan dengan algoritma lainnya (Anam et al., 2021). Adapun penelitian lain yang dilakukan mengenai analisis sentimen pada ulasan pengguna aplikasi bibit dan bareksa dengan algoritma KNN menunjukkan bahwa analisis sentimen dengan algoritma KNN dapat dilakukan khususnya dalam bidang finansial (Putra dan Safitri, 2021).

Pada penelitian ini, hal-hal yang berkaitan dengan sentimen finansial sangat mudah untuk ditemui di jejaring sosial seiring dengan perkembangan era digital dengan di dalamnya banyak memuat pernyataan-pernyataan, berita, dan opini seperti yang sudah dirangkum dan disajikan pada FiQA dan *The Financial PhraseBank*. Dengan segala kemudahan, setiap individu dapat memberikan opininya masing-masing terhadap pihak tertentu. Bentuk komplain atau pujian terhadap suatu kejadian finansial sangat mempengaruhi kredibilitas suatu pihak pada domain finansial. Tokoh-tokoh pada sektor finansial juga memiliki pengaruh besar seperti naik turunnya harga saham, nilai valuta asing, dan inflasi. Sentimen finansial yang muncul dapat berupa sentimen positif dan negatif. Sentimen

positif adalah opini yang menunjukkan kesan baik. Sedangkan, sentimen negatif adalah opini yang menunjukkan kesan buruk. Dengan adanya hal ini diperlukan analisis sentimen yang paling tepat sebagai bentuk evaluasi dari sentimen-sentimen publik yang diterima pihak terkait. Berkaitan dengan rumusan masalah yang dipaparkan dan penelitian terdahulu yang dijadikan sebagai bahan kajian, penelitian ini ditunjukkan untuk mendapatkan hasil analisis sentimen dengan algoritma terbaik melalui perbandingan performa algoritma *machine learning naive bayes*, *decision tree*, dan *K-nearest neighbor* terhadap kalimat finansial yang disajikan oleh FiQA dan *The Financial PhraseBank*.

METODE

Berisi metode penelitian yang digunakan dalam penelitian ini memuat rancangan penelitian, subjek penelitian, prosedur penelitian, instrumen penelitian, dan teknik analisis data.

Rancangan Penelitian

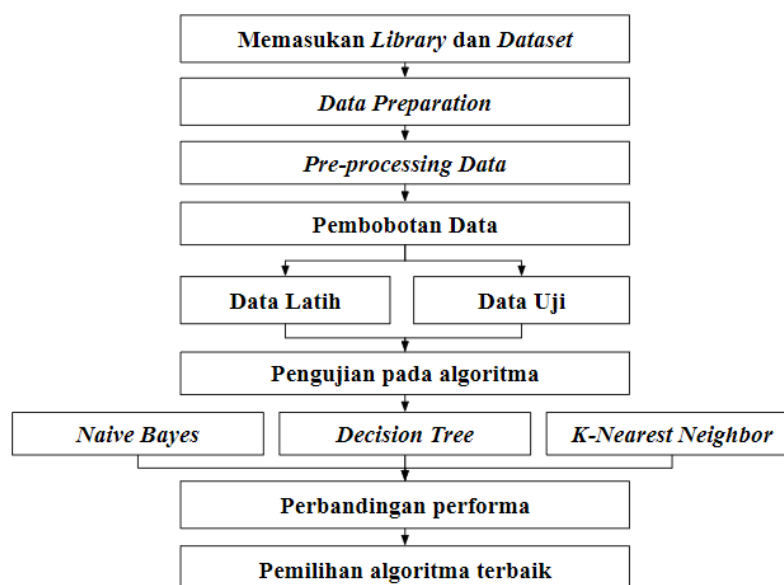
Rancangan Penelitian ini dilakukan dengan merancang sistem untuk melakukan pengujian terhadap masing-masing algoritma, yaitu *naive bayes*, *decision tree*, dan *K-nearest neighbor* dalam melakukan klasifikasi *data set* yang telah dibuat yaitu kalimat finansial pada FiQA dan *The Financial PhraseBank*. Ketiga algoritma tersebut akan diuji dengan membagi data menjadi data latih (80%) dan data uji (20%). Dalam prosesnya data latih akan digunakan terlebih dahulu untuk membentuk model. Selanjutnya setelah model terbentuk, akan digunakan data uji untuk evaluasi model.

Subjek Penelitian

Subjek penelitian pada penelitian ini adalah *data set Financial Statement* yang tersedia pada FiQA dan *The Financial PhraseBank* tahun 2022. Dataset tersebut bersumber dari situs *Kaggle Data set*.

Prosedur Penelitian

Prosedur yang dilakukan pada penelitian ini adalah (Gambar 1), (1) Memasukan *library* dan *data set* pada *platform kaggle*; (2) melakukan *data preparation* dengan tujuan untuk meninjau data terkait atribut, jumlah data, dan kecocokan dalam metode; (3) *Pre-processing data* dengan dengan tahapan *case folding*, *tokenizing*, *filtering*, dan *stemming*; (4) Pembobotan Data bertujuan untuk membobot setiap kata di dalam dokumen dengan metode TF-IDF; (5) Membagi menjadi data latih (80%) dan data uji (20%); (6) Pengujian pada ketiga algoritma *naive bayes*, *decision tree*, dan *K-nearest neighbor*; (7) Perbandingan performa dari nilai akurasi, presisi, dan *recall*; (8) Pemilihan algoritma terbaik berdasarkan nilai akurasi, presisi, dan *recall* yang paling tinggi.



Gambar 1. Skema penelitian

Instrumen Penelitian

Analisis dilakukan dengan menggunakan perangkat lunak *Python* pada penyedia platform analisis *Kaggle* dan *Google Collab*.

Teknik Analisis Data

Analisis dilakukan dengan mempertimbangkan tiga elemen analisis yaitu nilai akurasi, nilai presisi, dan nilai *recall* dari masing-masing algoritma. Setelah mendapatkan ketiga elemen tersebut analisis dilanjutkan dengan melakukan perbandingan dengan ketiga nilai tersebut pada tabel perbandingan performa dari algoritma *naïve bayes*, *decision tree*, dan *K-nearest neighbor*. Algoritma dengan nilai tertinggi akan dijadikan sebagai algoritma dengan performa terbaik dalam analisis sentimen.

Langkah analisis yang dilakukan adalah, (1) Melakukan pengumpulan data pada *data set* FIQA dan *The Financial PhraseBank*; (2) Melakukan *input library machine learning*; (3) Melakukan deskripsi data; (4) Melakukan *pre-processing data*: (a) *case folding*, (b) *tokenizing*, (c) *filtering*, (d) *stemming*; (5) Melakukan pembobotan dengan TF-IDF; (6) Membagi data latih (80%) dan data uji (20%); (7) Melakukan penyeimbangan jumlah data dengan metode SMOTE; (8) Melakukan evaluasi pengujian pada algoritma *naïve bayes*; (9) Melakukan evaluasi pengujian pada algoritma *decision tree*; (10) Melakukan evaluasi pengujian algoritma KNN; (11) Membandingkan hasil analisis sentimen dari setiap algoritma *machine learning* (nilai akurasi, presisi, dan *recall*); (12) Melakukan penarikan kesimpulan.

Klasifikasi pengujian analisis sentimen dilakukan dengan menggunakan *confusion matrix* dengan tujuan untuk menafsirkan nilai akurasi, presisi, dan *recall*. Tabel 1 merepresentasikan kemungkinan yang mungkin terjadi dari proses pengklasifikasian (Myers & Fawcett, 2010).

Tabel 1. *Confusion matrix*

Classifier		Kelas Data	
		Positif	Negatif
Prediksi Kelas	Positif	<i>True Positive</i>	<i>False Positive</i>
	Negatif	<i>False Negative</i>	<i>True Negative</i>

Proses klasifikasi kemungkinan yang dapat terjadi dari penggunaan *confusion matrix* diatas adalah, (1) *True Positive* (TP) merupakan klasifikasi ketika nilai prediksi dan fakta merupakan benar; (2) *True Negative* (TN) merupakan klasifikasi ketika nilai prediksi dan fakta merupakan salah; (3) *False Positive* (FP) merupakan klasifikasi ketika nilai prediksi adalah benar namun fakta merupakan salah; (4) *False Negative* (FN) merupakan klasifikasi ketika nilai prediksi adalah salah namun fakta merupakan benar.

Rumus yang digunakan untuk mencari nilai akurasi, presisi, dan *recall* dari Tabel 1 adalah,

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \tag{1}$$

$$Precision = \frac{TP}{TP+FP} \tag{2}$$

$$Recall = \frac{TP}{TP+FN} \tag{3}$$


Rumus untuk mencari nilai akurasi pada (1), presisi pada (2), dan *recall* pada (3) akan digunakan pada masing-masing algoritma *naïve bayes*, *decision tree*, dan *K-nearest neighbor*. Syarat utama dalam mendapatkan nilai tersebut adalah dengan terlebih dahulu mendapatkan nilai TP, TN, FP, dan FN pada tabel *confusion matrix* setiap algoritma (Mejova, 2009).

HASIL PENELITIAN

Analisis sentimen ini dilakukan dengan pengujian performa algoritma *machine learning naïve bayes*, *decision tree*, dan *K-nearest neighbor*. Dalam pengujian dilakukan pengujian dengan memunculkan *confusion matrix* dari masing-masing algoritma yang kemudian memunculkan nilai-nilai pengujian performa. Perbandingan performa dilihat dari perbandingan nilai akurasi, presisi, dan *recall* dari masing-masing algoritma.

Data Preparation

Dari total 2.712 sentimen yang terdapat di dalam *data set*, data dibagi ke dalam dua jenis sentimen. Kedua sentimen tersebut yaitu sentimen positif dan sentimen negatif seperti yang terlihat pada Gambar 2.



Gambar 2. Klasifikasi sentimen

Gambar 2 menunjukkan klasifikasi sentimen yang telah dikategorikan. Dapat diketahui bahwa dalam data set, terdapat 1.852 sentimen berkategori positif dan 860 sentimen berupa sentimen negatif.

Hasil Pengujian Algoritma Naive Bayes

Pengujian algoritma *naive bayes* dilakukan untuk mengetahui performa dari algoritma. Indikator keberhasilan pengujian adalah program dapat berjalan lancar, memunculkan nilai-nilai pengujian berupa nilai akurasi, presisi, dan *recall* dan tidak mengalami *error*. Setelah data pembobotan TF-IDF, *split* data menjadi data latih (80%) dan data uji (20%), melakukan *data balancing*, didapatkan tabel *confusion matrix* algoritma *naive bayes* seperti pada Tabel 2.

Tabel 2. Confusion matrix untuk model naive bayes

Classifier	Kelas Data	
	Positif	Negatif
Prediksi Kelas Positif	282	35
Prediksi Kelas Negatif	82	144

Tabel 2 menunjukkan bahwa nilai TP adalah 282, nilai FP adalah 35, nilai FN adalah 82 dan nilai TN adalah 144. Adapun hasil analisis sentimen mendapatkan nilai akurasi sebesar 0,7845 atau 78,45%; nilai presisi sebesar 0,8896 atau sebesar 88,96%; dan nilai *recall* sebesar 0,7747 atau sebesar 77,47%.

Hasil Pengujian Algoritma Decision Tree

Analisis menggunakan *decision tree* dilakukan untuk mengetahui performa terbaik dengan melihat nilai akurasi, presisi, dan *recall*. Dengan kata lain jika ketiga nilai tersebut semakin mendekati 100% dan tidak ada *error* maka nilai tersebut merupakan algoritma terbaik. Analisis menggunakan algoritma *decision tree* dilakukan dengan membagi data menjadi data latih (80%) dan data uji (20%) terhadap total data. Kemudian dilakukan proses pengolahan pada *data set* hasil *data balancing*. Dari hasil pengujian didapatkan *confusion matrix* untuk *decision tree* pada Tabel 3.

Tabel 3. Confusion matrix untuk model decision tree

Classifier	Kelas Data	
	Positif	Negatif
Prediksi Kelas Positif	308	65
Prediksi Kelas Negatif	56	144

Tabel 3 menunjukkan bahwa nilai TP adalah 308, nilai FP adalah 65, nilai FN adalah 56, dan nilai TN adalah 144. Adapun hasil analisis sentimen mendapatkan nilai akurasi sebesar 0,7772 atau 77,72%; nilai presisi sebesar 0,8257 atau sebesar 82,57%; dan nilai *recall* sebesar 0,8462 atau sebesar 84,62%.

Hasil Pengujian Algoritma *K-Nearest Neighbor*

Algoritma *K-nearest neighbor* sebelum dilakukan analisis perlu dilakukan pemilihan nilai *K* terlebih dahulu. Pada analisis ini nilai *k* adalah tiga dan lima dikarenakan jumlah dari kelas data adalah genap. Dari hasil pengujian didapatkan *confusion matrix* untuk *K-nearest neighbor* dengan *K* adalah tiga terdapat pada Tabel 4.

Tabel 4. *Confusion matrix* untuk model *K-nearest neighbor* (*K*=3)

Classifier		Kelas Data	
		Positif	Negatif
Prediksi Kelas	Positif	49	315
	Negatif	4	175

Tabel 4 menunjukkan bahwa nilai TP adalah 49, nilai FP adalah 315, nilai FN adalah 4, dan nilai TN adalah 175 dengan nilai akurasi sebesar 0,4125 atau 41,25%; nilai presisi sebesar 0,9245 atau sebesar 92,45%; dan nilai *recall* sebesar 0,1346 atau sebesar 13,46%.

Hasil pengujian didapatkan *confusion matrix* untuk *K-nearest neighbor* dengan nilai *k* adalah lima terdapat pada Tabel 5.

Tabel 5. *Confusion matrix* untuk model *K-nearest neighbor* (*K*=5)

Classifier		Kelas Data	
		Positif	Negatif
Prediksi Kelas	Positif	27	315
	Negatif	3	176

Tabel 5 menunjukkan bahwa nilai TP adalah 27, nilai FP adalah 337, nilai FN adalah 3, dan nilai TN adalah 176 dengan nilai akurasi sebesar 0,3738 atau 37,38%; nilai presisi sebesar 0,9 atau sebesar 90,00%; dan nilai *recall* sebesar 0,0741 atau sebesar 7,41%.

PEMBAHASAN

Hasil pengujian data FiQA dan *The Financial PhraseBank* dengan ketiga algoritma didapat setelah pengujian dengan melihat nilai akurasi, presisi, dan *recall* yang terdapat pada Tabel 6.

Tabel 6. Perbandingan hasil uji algoritma

No.	Algoritma	Akurasi	Presisi	Recall
1.	<i>Naive Bayes</i>	78,45%	88,96%	77,47%
2.	<i>Decision Tree</i>	77,72%	82,57%	84,62%
3.	<i>K-Nearest Neighbor</i> (<i>K</i> =3)	41,25%	92,45%	13,46%
4.	<i>K-Nearest Neighbor</i> (<i>K</i> =5)	37,38%	90,00%	7,41%

Tabel 6 menunjukkan perbandingan hasil uji algoritma dengan algoritma *naive bayes* memiliki nilai akurasi sebesar 78,45%, algoritma *decision tree* dengan nilai akurasi sebesar 77,72%, algoritma KNN (*k*=3) dengan nilai akurasi sebesar 41,25%, dan Algoritma KNN (*k*=5) dengan nilai akurasi sebesar 37,38%. Algoritma KNN mendapatkan nilai presisi paling besar dengan 92,45% menunjukkan bahwa tingkat *false positive* paling rendah. Pada perbandingan nilai *recall*, Algoritma *decision tree* memiliki nilai *recall* paling tinggi dengan nilai 84,62% menunjukkan bahwa *decision tree* memiliki *false negative* paling rendah.

Evaluasi terhadap nilai presisi menunjukkan bahwa algoritma yang memiliki nilai presisi paling tinggi adalah algoritma KNN. Nilai presisi yang tinggi menunjukkan algoritma tersebut memiliki *false positive* paling rendah dan mendukung terjadinya *true positive*. Hal ini menunjukkan bahwa algoritma memiliki kemampuan paling baik dalam

mengatasi keadaan ketika model memprediksi suatu sentimen merupakan sentimen positif namun faktanya merupakan sentiment negatif.

Pada nilai *recall* menunjukkan bahwa algoritma *decision tree* merupakan algoritma dengan nilai *recall* paling tinggi. Hal ini menunjukkan bahwa algoritma *decision tree* memiliki nilai *false negative* paling rendah dan mendukung terjadinya *false positive*, sehingga algoritma *decision tree* paling baik dalam mengatasi keadaan ketika model memprediksi sentimen adalah sentimen negatif namun faktanya sentimen tersebut merupakan sentimen positif.

Dalam kasus analisis sentimen kalimat finansial pada FiQA dan *The Financial PhraseBank* pemodelan yang diharapkan adalah ketika model dapat memprediksi secara benar baik itu memprediksi sentimen positif maupun negatif dan sesuai dengan faktanya bahwa sentimen tersebut merupakan sentimen positif atau negatif, sehingga pemodelan terbaik dapat dilakukan dengan memilih algoritma dengan nilai akurasi paling tinggi. Dengan demikian, algoritma *naïve bayes* muncul sebagai algoritma paling baik dengan nilai akurasi sebesar 78,45%. Hal ini serupa dengan hasil yang diperoleh Baihaqy et al. (2018), yang mendapati bahwa algoritma *naïve bayes* merupakan model yang lebih baik dibandingkan dengan algoritma *decision tree* dan KNN untuk mengklasifikasikan sentimen pelanggan E-commerce.

SIMPULAN

Pada analisis sentimen dengan melakukan pengujian performa pada algoritma *machine learning naïve bayes*, *decision tree*, dan *k-nearest neighbor* didapatkan bahwa ketiga algoritma tersebut dapat digunakan dalam melakukan analisis sentimen kalimat finansial pada FiQA dan *The Financial PhraseBank*. Algoritma *naïve bayes* mengungguli algoritma lainnya karena memiliki nilai akurasi paling tinggi dengan nilai 78,45%.

DAFTAR PUSTAKA

- Ahmad, M., Aftab, S., Muhammad, S. S., & Ahmad, S. (2017). Machine learning techniques for sentiment analysis: A review. *International Journal Of Multidisciplinary Sciences And Engineering*, 8(3), 27-32. <https://api.semanticscholar.org/CorpusID:244951876>
- Anam, M. K., Pikir, B. N., Firdaus, M. B., Erlinda, S., & Agustin, A. (2021). Penerapan naïve bayes classifier, k-nearest neighbor (knn) dan decision tree untuk menganalisis sentimen pada interaksi netizen dan pemerintah. *MATRIK: Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, 21(1), 139-150. <https://doi.org/10.30812/matrik.v21i1.1092>
- Baihaqy, A., Sfenrianto, S., Nainggolan, K., & Kaburuan, E. R. (2018). Sentiment analysis about e-commerce from tweets using decision tree, k-nearest neighbor, and naïve bayes. *2018 International Conference on Orange Technologies (ICOT), 2018*, 1-6, <https://doi.org/10.1109/ICOT.2018.8705796>
- El Naqa, I. & Murphy, M. J. (2015). What is machine learning?. *In machine learning in radiation oncology*, 3-11. Springer, Cham. http://dx.doi.org/10.1007/978-3-319-18305-3_1
- Institute, M. (2018). Pengenalan Terhadap Machine Learning. <https://medium.com>
- Jadhav, S. D. C. (2016). Comparative Study of K-NN, Naive bayes and decision tree classification techniques. *International Journal*, 5(1), 1842-1845. <https://doi.org/10.21275/v5i1.nov153131>
- Maia, M., Handschuh, S., Freitas, A., Davis, B., McDermott, R., Zarrouk, M., & Balahur, A. (2018). Www'18 open challenge: financial opinion mining and question answering. *In Companion proceedings of the the web conference 2018*, 1941-1942. <http://dx.doi.org/10.1145/3184558.3192301>
- Malo, P., Sinha, A., Takala, P., Ahlgren, O., & Lappalainen, I. (2013, December). Learning the roles of directional expressions and domain concepts in financial news analysis. *In 2013 IEEE 13th international conference on data mining workshops*, 945-954. IEEE. <http://dx.doi.org/10.1109/ICDMW.2013.36>

- Mejova, Y. (2009). Sentiment analysis: An overview. University of Iowa, Computer Science Department. <http://www.ijreat.org/Papers%202013/Issue4/IJREATV1I4016.pdf>
- Muhammad, A. N., Bukhori, S., & Pandunata, P. (2019). Sentimen analysis of positive and negative of youtube comments using naive bayes–support vector machine (NBSVM) classifier. *International Conference on Computer Science, Information Technology, and Electrical Engineering (ICQMITEE)*, 199-205. <https://doi.org/10.1109/ICOMITEE.2019.8920923>
- Myers, V., & Fawcett, J. (2010). A template matching procedure for automatic target recognition in synthetic aperture sonar imagery. *IEEE Signal Processing Letters*, 17(7), 683-686. <http://dx.doi.org/10.1109/LSP.2010.2051574>
- Pang, B. & Lee, L. (2008). Opinion mining and sentiment analysis. *Foundation and Trends in Information Retrieval*, 2(1-2), 1–135. *Northern: Northern Illinois University Center for Southeast Asian Studies*. <https://doi.org/10.1561/15000000011>
- Puspita, R., & Widodo, A. (2021). Perbandingan metode knn, decision tree, dan naïve bayes terhadap analisis sentimen pengguna layanan BPJS. *J. Inform. Univ. Pamulang*, 5(4), 646. <https://dx.doi.org/10.32493/informatika.v5i4.7622>
- Putra, A. D. A., & Juanita, S. (2021). Analisis Sentimen pada Ulasan pengguna Aplikasi Bibit Dan Bareksa dengan Algoritma KNN. *JATISI (Jurnal Teknik Informatika dan Sistem Informasi)*, 8(2), 636-646. <https://doi.org/10.35957/jatisi.v8i2.962>
- Singh, P. K., & Husain, M. S. (2014). Methodological study of opinion mining and sentiment analysis techniques. *International Journal on Soft Computing (IJSC)*, 5(1), 11-21. <https://doi.org/10.5121/ijsc.2014.5102>
- Wiebe, M., Hassan, A., & Korashy, H. (2014). Sentimen analysis algorithms and applications: A survey. *Ain Shams engineering journal*, 5(4), 1093-1113. <http://dx.doi.org/10.1016/j.asej.2014.04.011>