

Klasifikasi Sentimen Tweet Masyarakat Terhadap Kendaraan Listrik Menggunakan Support Vector Machine

Nuari Ananda^{1*}, Muhammad Fikry², Yusra³, Lestari Handayani⁴, Iwan Iskandar⁵

¹²³⁴⁵Universitas Islam Negeri Sultan Syarif Kasim, Jl. HR. Soebrantas KM. 18 No. 155, Kec. Tampan, Pekanbaru, Riau, Indonesia, 28129

e-mail: ¹11950115151@students.uin-suska.ac.id, ²muhammad.fikry@uin-suska.ac.id, ³yusra@uin-suska.ac.id, ⁴lestari.handayani@uin-suska.ac.id, ⁵iwan.iskandar@uin-suska.ac.id

*Corresponding author

Submitted Date: December 15th, 2023

Reviewed Date: December 19th, 2023

Revised Date: December 23th, 2023

Accepted Date: December 27th, 2023

Abstract

Sentiment analysis involves using classification algorithms to analyze public opinions and feelings in text. Within the automobile industry, electric vehicles (EVs) stem from the circular economy and represent a novel technology under investigation in sentiment classification studies. The Support Vector Machine (SVM) algorithm is commonly used in this research due to its superior accuracy compared to other algorithms. The goal of this study is to apply SVM variable selection techniques to enhance sentiment analysis quality. Python is the programming language used to build the sentiment classification model, which involves feature selection using TF-IDF, training with cross-validation and grid search, evaluation using a confusion matrix, and storing the dataset in a MySQL database. The research focuses on the sentiment classification of 3000 public tweets about electric vehicles on Twitter. Through various scenarios, it was observed that the accuracy of sentiment classification varied depending on factors such as randomizing data, handling negation, and using different types of features like unigrams or bigrams. The highest accuracy achieved was 84% using a scenario with random data, negation handling, and unigram features. Overall, this research highlights the impact of randomizing data and selecting appropriate features on sentiment classification accuracy for electric vehicles on Twitter.

Keywords: sentiment analysis, electric vehicles, Support Vector Machine, negation.

Abstrak

Analisis sentimen adalah studi tentang komputer yang mengubah item dan kualitasnya menjadi teks, yang mencakup opini dan perasaan publik. Dalam pembelajaran mesin, algoritma klasifikasi membantu mengidentifikasi sentimen positif dan negatif dalam pernyataan atau dokumen. Kendaraan listrik merupakan produk dari circular economy dan juga teknologi baru dalam dunia otomotif, dalam penelitian klasifikasi sentimen, peneliti menggunakan algoritma Support Vector Machine (SVM) karena memiliki akurasi yang lebih baik dibandingkan algoritma lainnya. Penelitian ini bertujuan untuk meningkatkan kualitas analisis sentimen dengan menggunakan metode pemilihan variabel SVM. Bahasa pemrograman Python digunakan untuk membangun model, seleksi fitur menggunakan TF-IDF, menggunakan Cross Validation dan grid search untuk pelatihan, confusion matrix untuk evaluasi, dan menggunakan basis data MySQL untuk menyimpan dataset. Penelitian ini melibatkan klasifikasi sentimen dari 3000 tweet publik tentang kendaraan listrik di Twitter. Pada pengujian yang dilakukan dengan delapan skenario, akurasi terendah sebesar 81.3% dengan skenario tanpa data acak, tanpa penanganan negasi, dan bigram kemudian akurasi tertinggi sebesar 84% dengan skenario data acak, menggunakan penanganan negasi, dan unigram, dengan jumlah fitur unigram 182 dan bigram 116 setelah dilakukan seleksi fitur. Dari kedelapan skenario tersebut dapat disimpulkan bahwa pengacakan data dan fitur berupa unigram maupun bigram mempengaruhi akurasi klasifikasi sentimen pada kasus kendaraan listrik di Twitter.

Kata Kunci: analisis sentimen, kendaraan listrik, Support Vector Machine, negasi.



1. Pendahuluan

Perusahaan otomotif selalu melakukan inovasi untuk menarik minat konsumen maka dalam proses pengembangan perlu dilakukan tahap evaluasi dan memperhitungkan respon konsumen dari produk sebelumnya demi mendapatkan keuntungan untuk produk selanjutnya dan untuk membuat perusahaan tetap dapat bersaing dengan perusahaan lainnya (Nai et al., 2022). Bisnis otomotif memiliki pasar yang besar hampir di seluruh dunia di mana pada tahun 2020 penjualan kendaraan mencapai 56,000,700 juta unit kendaraan dengan pasar yang sebesar itu maka bisnis otomotif sangat menguntungkan bagi para investor yang ingin berbisnis di dunia otomotif (Impressum, 2021). Pasar otomotif global diperkirakan sekitar 13 milyar dolar dan berkembang pada tingkat sekitar 100 juta dolar setiap tahun (Jefferson et al., 2018). Verband der Automobilindustrie memperkirakan bahwa total penjualan mobil di seluruh dunia pada tahun 2021 akan tumbuh sebesar 9% menjadi 73,8 juta mobil (German Association of the Automotive Industry, 2021).

Akibatnya, ini merupakan indikator positif bagi industri otomotif dan industri terkait dan pertanda buruk untuk kualitas udara (Vongurai, 2020). Para pihak yang terkait dalam Perjanjian Paris 2015 membuat komitmen untuk menjaga pemanasan global di bawah 2 derajat Celcius dan berupaya menjaga kenaikan suhu hingga 1,5 derajat Celcius dibandingkan dengan masa pra-industri (Welsby et al., 2021). Untuk menjaga kenaikan suhu di bawah 1,5 derajat celsius, bagaimanapun penurunan yang signifikan dalam penggunaan bahan bakar fosil, yang terus mendominasi sistem energi dunia harus dicapai (Mauleón, 2021).

Kendaraan listrik (electric vehicles) ini merupakan produk ekonomi sirkular dan juga teknologi baru di dunia otomotif. Produk ekonomi sirkular semakin populer sebagai model alternatif yang mengurangi penipisan sumber daya, pemborosan, dan emisi di bidang akademik, bisnis, dan pembuatan kebijakan (Geissdoerfer et al., 2020). Jenis sel bahan bakar yang mampu memaksimalkan kinerja sistem sangat penting di antara elemen-elemen yang tercakup di dalamnya. Perlu juga bahwa jenis pemrosesan bahan bakar yang digunakan dapat diolah secara terus menerus (Olabi et al., 2020).

Dalam penelitian terkait, Bhatnagar dan Choubey menemukan bahwa tagar "#Tesla" memiliki sentimen lebih positif daripada produsen

lain. Mereka melakukan ini menggunakan analisis sentimen berbasis tweet menggunakan skor TF-IDF dan *Naive Bayes Classifier* dengan akurasi 77% (Bhatnagar & Choubey, 2021). Pada penelitian yang dilakukan oleh Handayani dan Muastikasari, mereka melakukan klasifikasi sentimen tweet tentang mobil listrik menggunakan RNN menggunakan *Confusion Matrix* dengan *Precision* 0.618, *Recall* 0.507 dan Akurasi 72% (Handayani & Mustikasari, 2020). Dalam penelitian lain yang dilakukan oleh Costello dengan menggunakan data dari komentar video pada youtube dengan *query* "mobil listrik". Dari hasil penelitian sentimen dengan metode *Support Vector Machine* dengan *feature selection Chi-squared* didapat hasil akurasi sebesar 70% (Costello & Lee, 2020).

Dalam melakukan metode klasifikasi sentimen penulis menggunakan algoritma *Support Vector Machine* penggunaan algoritma ini karena dalam pengklasifikasian memiliki akurasi yang lebih tinggi dari pada algoritma pengklasifikasian yang lainnya. Dalam penelitian yang dilakukan oleh Endang Supriyati untuk mengklasifikasikan tema pada jus 30 Al-Qur'an. Dari hasil penelitian tersebut *Support Vector Machine* mendapatkan hasil terbaik dengan akurasi 75,84%, klasifikasi *Decision Tree* dengan akurasi 74,34%, dan *Naive Bayes* dengan akurasi 66,29% (Supriyati & Iqbal, 2018). Pada penelitian yang dilakukan oleh Ahmad Santoso untuk mengklasifikasikan sentimen tentang mobil listrik. Klasifikasi dilakukan dengan algoritma *Support Vector Machine* dengan data yang diperoleh dari twitter dengan *query* "Mobil Listrik". Dari hasil klasifikasi menggunakan algoritma *Support Vector Machine* didapatkan hasil akurasi sebesar 82,51% (Santoso et al., 2022).

Kendaraan listrik merupakan salah satu solusi untuk mengurangi emisi gas rumah kaca dan polusi udara yang dihasilkan oleh kendaraan bermotor konvensional. Namun, kendaraan listrik masih belum banyak diminati oleh masyarakat karena berbagai faktor, seperti harga, ketersediaan infrastruktur, dan persepsi.

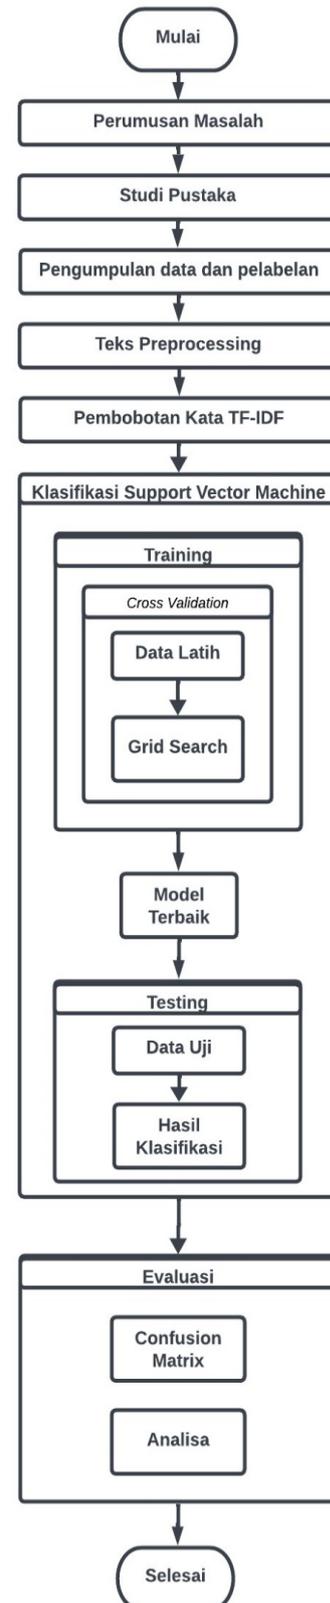
Oleh karena itu, penelitian ini bertujuan untuk menganalisis sentimen masyarakat terhadap kendaraan listrik dengan menggunakan media sosial Twitter sebagai sumber data. Twitter, salah satu platform media sosial yang populer, banyak digunakan oleh orang untuk berbagi pengalaman, pendapat, dan informasi. Dengan menggunakan metode klasifikasi sentimen berbasis *Support Vector Machine* (SVM), penelitian ini dapat mengidentifikasi apakah suatu tweet bersifat

positif, atau negatif terhadap kendaraan listrik. Selain itu, Penelitian ini juga menyelidiki komponen yang mempengaruhi kinerja model klasifikasi sentimen, seperti dataset, fitur, dan preprosesing yang digunakan.

Dengan menyediakan dataset untuk peneliti yang tertarik dengan tema penelitian terkait, hasil penelitian ini diharapkan dapat menjadi referensi bagi peneliti yang akan datang. Penelitian ini juga dapat menunjukkan performa dari metode SVM dalam melakukan klasifikasi tweet tentang kendaraan listrik, serta aspek-aspek yang dapat meningkatkan performa klasifikasi tersebut.

2. Metode Penelitian

Metodologi penelitian adalah rangka kerja sistematis dari penelitian untuk mencapai tujuan. Untuk penelitian yang terstruktur, setiap proses dan tahapan harus diikuti. Metode penelitian berfungsi sebagai garis besar untuk melakukan penelitian, memungkinkan setiap langkah dilakukan secara sistematis dari awal hingga akhir. Berikut adalah langkah-langkah penelitian:



Gambar 1. Metodologi Penelitian
Berikut ini adalah alur penjelasan dari flowchart tahapan penelitian.

2.1 Perumusan Masalah

Dalam metodologi penelitian yang akan dilakukan, langkah pertama adalah perumusan masalah. Pada titik ini, masalah dirumuskan, diperiksa, dan diidentifikasi dasar dari masalah tersebut. Salah satu masalah yang akan dibahas adalah bagaimana menggunakan teknik *Support Vector Machine* untuk mengkategorikan sentimen masyarakat terhadap kendaraan listrik di media sosial Twitter dan mengetahui seberapa akurat teknik tersebut.

2.2 Studi Pustaka

Untuk mendapatkan semua informasi dan referensi yang diperlukan untuk penelitian, penyelidikan pustaka dilakukan. Informasi di dapat dari buku, jurnal, kertas internasional, YouTube, dan referensi lainnya.

2.3 Pengumpulan dan Pelabelan Data

Studi ini menggunakan *crowdsourcing* untuk mengumpulkan data tweet tentang pendapat masyarakat Indonesia tentang kendaraan listrik. Pengumpulan data dilakukan melalui crawling menggunakan bahasa pemrograman Python dan kata kunci seperti "kendaraan listrik", "mobil listrik", "motor listrik", "Hyundai Ioniq", "motor gesit", dan lainnya. Selanjutnya, sebanyak 3000 data dilabeli secara manual menjadi dua kategori: positif dan negatif. Untuk analisis selanjutnya, set data yang dikumpulkan akan dibagi menjadi dua puluh persen data uji dan delapan puluh persen data latih.

2.4 Text Preprocessing

Penelitian ini menyelidiki lima tahapan *text preprocessing*, yang paling penting di mana data dibersihkan dan disiapkan sebelum proses klasifikasi. Tahapan ini termasuk *remove URL*, *delete username*, *removing hashtags*, *remove single character*, *remove punctuation*, *case folding*, *negation handling* dan *stopword removal* untuk memperoleh hasil *text preprocessing* terbaik (Renas Madya Pradhana, 2021).

Text Preprocessing diperlukan untuk membersihkan data dari informasi yang tidak relevan. Proses ini bertujuan untuk memastikan data yang digunakan bebas dari noise dan lebih terstruktur, dengan dimensi yang lebih kecil lebih lanjut (Rivki & Bachtiar, 2017). Tahapan *Text Preprocessing* melibatkan:

1. *Cleaning*: Menghilangkan atribut atau tanda baca yang tidak berkaitan.
2. *Case Folding*: Mengubah huruf besar menjadi huruf kecil pada komentar.

3. *Normalisasi*: Mengembalikan bentuk penulisan kata sesuai dengan Kamus Besar Bahasa Indonesia (KBBI).
4. *Negation handling*: Inversi makna kata-kata negasi untuk memastikan pemahaman yang akurat terhadap makna sebenarnya dari pernyataan yang mengandung negasi.
5. *Filtering*: Menghilangkan kata-kata tanpa makna atau stop word.
6. *Stemming*: Memotong imbuhan atau mengembalikan kata berimbuhan menjadi kata dasar, untuk mengembalikan kata-kata dengan variasi morfologi menjadi bentuk kata baku atau dasar.
7. *Tokenizing*: Membagi teks pada dokumen menjadi token.

Table 1. Normalisasi

Sebelum Normalisasi	Sesudah Normalisasi
drma	dari mana
mmng	memang
naek	naik

Table 2. Negasi

Sebelum di Negasi	Sesudah di Negasi
tidak asal2an	beraturan
belum ada	nihil
tidak mendukung	menolak

2.5 Pembobotan Kata TF-IDF

Dalam klasifikasi dokumen teks, digunakan metode *Term Frequency-Inverse Document Frequency* (TF-IDF) untuk pembobotan kata, yang menghitung bobot setiap kata yang di ekstrak. Metode ini umum digunakan dalam *Information Retrieval* dan dianggap akurat (Amrizal, 2018). Tujuan pembobotan kata adalah untuk memberikan nilai bobot pada setiap kata. Jumlah kata dalam dokumen diwakili oleh frekuensi kata, dan frekuensi balik dokumen diwakili oleh frekuensi kata yang muncul di seluruh dokumen. Sebelum menghitung bobot IDF(1), persamaan khusus digunakan untuk menghitung bobot TF-IDF.

$$IDF_t = \log \frac{d}{df_t} \quad (1)$$

Keterangan:

IDF_t = Bobot IDF ke t dokumen d

df_t = Jumlah dokumen yang mengandung term t. d

= Jumlah dokumen keseluruhan selanjutnya menghitung bobot TF-IDF dengan persamaan berikut(2):

$$W_{at} = tf_t \times IDF_t \quad (2)$$

Keterangan:

W_{at} = Jumlah *term* ke t dalam dokumen d

tf_t = Jumlah kali kata t muncul dalam dokumen t

IDF_t = Jumlah IDF yang dihitung sebelumnya (Maulidina, 2020).

2.6 Klasifikasi Support Vector Machine

Mengelola informasi dari banyak dokumen memerlukan metode otomatis untuk mengorganisir dan mengklasifikasinya agar pencarian informasi relevan menjadi lebih mudah. Klasifikasi dokumen teks melibatkan teknik seperti *Naïve Bayes*, KNN, dan SVM. Terdapat dua metode klasifikasi: *supervised*, yang menggunakan label sebelumnya, dan *unsupervised*, yang mengenali data secara *real-time* saat disajikan. *Supervised classification* memberikan kontrol terhadap kelas informasional dan keakuratan klasifikasi, sedangkan *unsupervised classification* mengurangi kesalahan operator dan memandang *unique classes* sebagai unit yang berbeda (Septiani et al., 2019).

Tahap klasifikasi melibatkan pengujian yang dilakukan menggunakan metode vector support machine (SVM) untuk mengidentifikasi sentimen dari tweet. Proses klasifikasi dilakukan menggunakan bahasa pemrograman Python. Kemudian, akurasi yang diperoleh diuji lagi menggunakan matriks kecacauan untuk memastikan bahwa hasilnya sesuai dengan perhitungan *confusion matrix*.

Untuk klasifikasi, analisis regresi, prediksi, dan penilaian sistem, *Support Vector Machines* (SVM) adalah metode pembelajaran untuk analisis data dan pengenalan pola. SVM termasuk dalam *supervised learning* dan melibatkan tahap pelatihan dengan *sequential training SVM* dan pengujian. SVM dapat menyelesaikan permasalahan linier dan non-linier dengan menggunakan konsep kernel pada ruang berdimensi tinggi. Konsep ini melibatkan pencarian *hyperplane* yang memaksimalkan margin antar label data, berfungsi sebagai pemisah antara dua kelompok class +1 dan class -1 dengan pola masing-masing. Tujuan SVM adalah mencari *hyperplane* terbaik untuk klasifikasi (Athira Luqyana et al., 2018).

2.7 K-Fold Cross Validation

Tujuan validasi adalah untuk mengevaluasi kinerja model klasifikasi melalui metode *k-Fold Cross Validation*. Tujuan utama dari metode ini adalah untuk mengukur kinerja model dengan membagi data menjadi subset pelatihan (*training*)

yang akan dilakukan *cross validation* untuk mendapatkan model terbaik dan subset pengujian (*testing*) digunakan untuk melakukan pengujian pada model terbaik dari hasil *Cross Validasi*. *K-Fold Cross Validation* memastikan bahwa model dievaluasi secara menyeluruh dengan mengulangi proses pelatihan dan pengujian pada setiap subset data secara bergantian.

2.8 Evaluasi

Tahap selanjutnya adalah mengevaluasi temuan dari berbagai pengujian. Kinerja model yang dihasilkan diukur melalui evaluasi. Matriks klasifikasi *confusion matrix* digunakan dalam penelitian ini sebagai pendekatan pengukuran kinerja. *Confusion matrix* adalah tabel yang menunjukkan berapa banyak prediksi yang benar dan salah dari set data tertentu untuk menjelaskan kinerja model *machine learning*.

K-Fold Cross Validation membagi data menjadi k bagian dan menggunakan setiap bagian sebagai data uji untuk memastikan bahwa model tidak memprediksi data terlalu cepat. Model diuji pada setiap bagian, dan akurasi dihitung, kemudian di-total dan dibagi dengan jumlah *fold* (Nasution & Hayaty, 2019).

Confusion matrix merupakan suatu tabel yang memperlihatkan jumlah prediksi yang tepat dan tidak tepat dari data uji oleh model klasifikasi. Teknik ini sangat efektif untuk mengevaluasi efisiensi model klasifikasi, khususnya dalam situasi dengan berbagai kelas. *Confusion matrix* cocok digunakan dalam penelitian untuk mengevaluasi akurasi hasil klasifikasi dari model yang telah dibuat (Rivki & Bachtiar, 2017).

Table 3. *Confusion Matrix*

Kelas	Terklasifikasi Positif	Terklasifikasi Negatif
Positif	TP(True Positif)	FP(False Positif)
Negatif	FN(False Negatif)	TN(True Negatif)

Akurasi adalah rasio dari total prediksi yang benar dari semua data(3).

$$Akurasi = \frac{(TP + TN)}{TP + TN + FP + FN} \times 100 \quad (3)$$

Precision merupakan ukuran seberapa tepat hasil suatu model. Persamaannya adalah membandingkan data positif asli dengan semua data positif (4).



$$Precision = \frac{TP}{TP + FP} \times 100 \quad (4)$$

Recall merupakan ukuran kelengkapan model. Persamaan *recall* menunjukkan perbandingan antara contoh yang benar-benar positif asli dan total contoh yang benar-benar positif (5).

$$Recall = \frac{TP}{TP + FN} \times 100 \quad (5)$$

Skor F1 adalah rata-rata harmonis dari presisi dan recall (6).

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (6)$$

Keterangan :

TP : jumlah data yang diklasifikasikan sebagai positif.

TN : jumlah data yang dikategorikan negatif.

FP : Jumlah data yang tidak memiliki kelas positif dikategorikan sebagai negatif.

FN : jumlah data dengan kelas negatif diklasifikasikan sebagai positif (Nasution & Hayaty, 2019).

3. Hasil dan Pembahasan

Dalam penelitian ini, saya melakukan delapan skenario pengujian dengan memvariasikan tiga komponen, yaitu urutan data, penanganan negasi, dan parameter *N-gram*. Komponen-komponen ini dipilih karena saya berasumsi bahwa mereka memiliki pengaruh terhadap kinerja klasifikasi sentimen dalam analisis teks. Saya menggunakan data yang teracak dan data yang terurut, di mana 1500 data pertama berlabel positif dan 1500 data setelahnya berlabel negatif.

Saya juga membandingkan hasil klasifikasi antara data yang dilakukan penanganan negasi dan normalisasi dengan kamus manual yang saya rancang dan data yang tidak dilakukan penanganan negasi. Selain itu, saya menggunakan parameter *N-gram* dengan nilai *unigram* dan *bigram* untuk melihat pengaruhnya terhadap akurasi klasifikasi.

Dengan melakukan delapan skenario pengujian ini, saya ingin mengetahui komponen mana yang paling berkontribusi dalam meningkatkan kinerja klasifikasi sentimen dalam analisis teks. Saya secara khusus merancang dan mengimplementasikan kamus manual untuk penanganan negasi dan normalisasi, untuk memperkuat klasifikasi sentiment dalam analisis teks.

Melalui penggunaan 3000 data tweets yang terbagi menjadi 1500 tweets positif dan 1500 tweets negatif, sebuah pengujian dilakukan. Pengujian ini menggunakan fitur seleksi berdasarkan hasil pembobotan TF-IDF dengan ambang batas 0,001. Selanjutnya, 3000 dataset tersebut dibagi menjadi data latih dan data uji dengan perbandingan 80:20. Selanjutnya, data latih dilatih menggunakan teknik *cross validation* dengan nilai $K=10$ untuk menemukan model terbaik melalui pencarian grid. Model terbaik yang diperoleh dari pelatihan kemudian diuji pada data uji untuk mengetahui hasil evaluasi dari akurasi.

3.1 Pengujian Pertama

Pengujian pertama dengan skenario dataset terurut, tanpa negasi *handling*, dan dengan *unigram*. Berikut hasil *Confusion Matrix*:

Table 4. *Confusion Matrix* dari data terurut, tanpa negasi *handling*, dan *unigram*

Pengujian	True Positif	True Negatif	Class Precision
Pred. Positif	253	62	80.3%
Pred. Negatif	39	246	86.3%
Class Recall	86.6%	79.9%	

Hasil akurasi sebesar 83,2%.

3.2 Pengujian Kedua

Pengujian kedua dengan skenario dataset terurut, tanpa negasi *handling*, dan dengan *bigram*. Berikut hasil *Confusion Matrix*.

Table 5. *Confusion Matrix* dari data terurut, tanpa negasi *handling*, dan *bigram*

Pengujian	True Positif	True Negatif	Class Precision
Pred. Positif	252	72	77.8%
Pred. Negatif	40	236	85.5%
Class Recall	86.3%	76.6%	

Hasil akurasi sebesar 81,6%.

3.3 Pengujian Ketiga

Pengujian ketiga dengan skenario dataset terurut, dengan negasi *handling*, dan dengan *unigram*. Berikut hasil *Confusion Matrix*.



Table 6. *Confusion Matrix* dari data terurut, dengan negasi *handling*, dan *unigram*

Pengujian	True Positif	True Negatif	Class Precision
Pred. Positif	252	61	80.5%
Pred. Negatif	40	247	86.1%
Class Recall	86.3%	80.2%	

Hasil akurasi sebesar 83,2%.

3.4 Pengujian Keempat

Pengujian keempat dilakukan dengan skenario dataset terurut, dengan negasi *handling*, dan dengan *bigram*. Berikut hasil *Confusion Matrix*.

Table 7. *Confusion Matrix* dari data terurut, dengan negasi *handling*, dan *bigram*

Pengujian	True Positif	True Negatif	Class Precision
Pred. Positif	252	71	78%
Pred. Negatif	40	237	85.6%
Class Recall	86.3%	76.9%	

Hasil akurasi sebesar 81,5%.

3.5 Pengujian Kelima

Pengujian kelima dilakukan dengan skenario dataset diacak, tanpa negasi *handling*, dan dengan *unigram*. Berikut hasil *Confusion Matrix*.

Table 8. *Confusion Matrix* dari data di acak, tanpa negasi *handling*, dan *unigram*

Pengujian	True Positif	True Negatif	Class Precision
Pred. Positif	277	43	86,6%
Pred. Negatif	55	225	80,4%
Class Recall	83,4%	84%	

Hasil akurasi sebesar 83,7%.

3.6 Pengujian Keenam

Pengujian keenam dilakukan dengan skenario dataset di acak, tanpa negasi *handling*, dan dengan *bigram*. Berikut hasil *Confusion Matrix*.

Table 9. *Confusion Matrix* dari data di acak, tanpa negasi *handling*, dan *bigram*

Pengujian	True Positif	True Negatif	Class Precision
Pred. Positif	252	64	79,7%
Pred. Negatif	43	241	84,9%
Class Recall	85,4%	79%	

Hasil akurasi sebesar 82,2%.

3.7 Pengujian Ketujuh

Pengujian ketujuh dilakukan dengan skenario dataset di acak, dengan negasi *handling*, dan dengan *unigram*. Berikut hasil *Confusion Matrix*.

Table 10. *Confusion Matrix* dari data di acak, dengan negasi *handling*, dan *unigram*

Pengujian	True Positif	True Negatif	Class Precision
Pred. Positif	246	51	82,8%
Pred. Negatif	45	258	85,1%
Class Recall	83,5%	84,5%	

Hasil akurasi sebesar 84%.

3.8 Pengujian Kedelapan

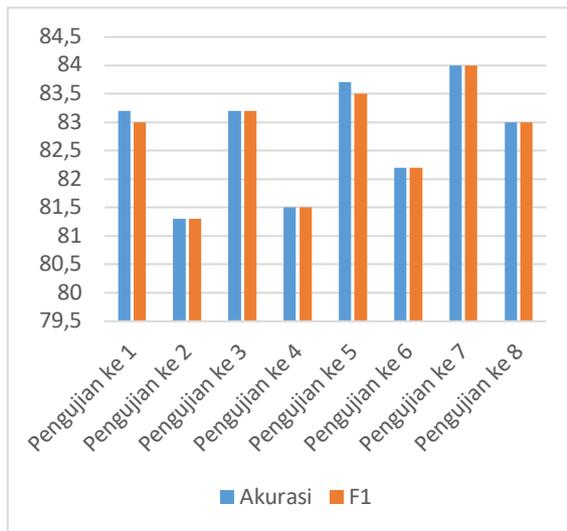
Pengujian kedelapan dilakukan dengan skenario dataset di acak, dengan negasi *handling*, dan dengan *bigram*. Berikut hasil *Confusion Matrix*.

Table 11. *Confusion Matrix* dari data di acak, dengan negasi *handling*, dan *bigram*

Pengujian	True Positif	True Negatif	Class Precision
Pred. Positif	259	69	79%
Pred. Negatif	33	239	87,9%
Class Recall	88,7%	77,6%	

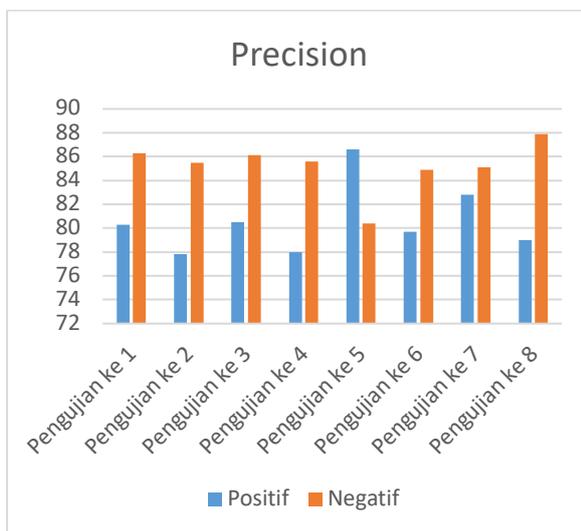
Hasil akurasi sebesar 83%.

3.9 Hasil Penelitian



Gambar 2. Hasil Akurasi 8 Pengujian

Gambar 2 menunjukkan hasil akurasi dari delapan skenario pengujian yang dilakukan dalam penelitian ini. Dari delapan skenario pengujian, skenario ke 7 memberikan akurasi tertinggi, yaitu 84%. Skenario ke 7 menggunakan dataset yang diacak, melakukan negasi handling pada dataset, dan menggunakan unigram sebagai fitur. Hal ini menunjukkan bahwa skenario ke 7 mampu menghasilkan model SVM yang paling optimal dalam melakukan analisis sentimen teks.

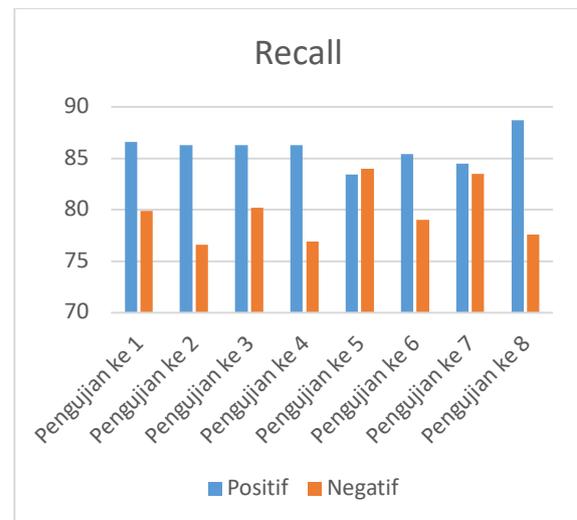


Gambar 3. Hasil Precision dari 8 pengujian

Pada Gambar 3 pengacakan data dapat mengurangi bias dan meningkatkan validitas. Dari delapan skenario pengujian dengan menggunakan data yang diacak. Hasil pengujian menunjukkan bahwa ada perbedaan nilai *precision* antara

skenario pengujian. Seberapa akurat model SVM mengklasifikasikan teks menjadi positif atau negatif disebut *precision*.

Dengan nilai *precision* tinggi, model SVM memiliki tingkat kesalahan yang rendah dalam mengklasifikasikan teks. Dari delapan skenario pengujian, skenario ke 5 memberikan nilai *precision* positif yang paling tinggi, yaitu 86,6%. Ini berarti bahwa model SVM pada skenario ke 5 mampu mengenali teks positif dengan baik. Sementara itu, skenario ke 8 memberikan nilai *precision* negatif yang paling tinggi, yaitu 87,9%. Ini berarti bahwa model SVM pada skenario ke 8 mampu mengenali teks negatif dengan baik.



Gambar 4. Hasil Recall dari 8 pengujian

Dari gambar 4 nilai *recall* yang tinggi menunjukkan bahwa model SVM memiliki kemampuan yang luar biasa untuk mengklasifikasikan teks. Dari delapan skenario pengujian, skenario ke 8 memberikan nilai *recall* positif yang paling tinggi, yaitu 88,7%. Ini berarti bahwa model SVM pada skenario ke 8 mampu mengklasifikasikan hampir semua teks positif dengan benar. Sementara itu, skenario ke 5 memberikan nilai *recall* negatif yang paling tinggi, yaitu 85%. Ini berarti bahwa model SVM pada skenario ke 5 mampu mengklasifikasikan sebagian besar teks negatif dengan benar.

4. Kesimpulan

Hasil pengujian menunjukkan bahwa penanganan *negasi* dan fitur *unigram* memberikan pengaruh positif terhadap akurasi, *precision*, dan *recall* SVM. Hal ini menunjukkan bahwa penanganan negasi dapat membantu SVM untuk mengenali konteks dan makna kata-kata negatif

dalam kalimat, seperti tidak, bukan, atau kurang. Fitur *unigram* dapat memberikan informasi yang cukup untuk mengklasifikasikan sentimen, tanpa perlu mempertimbangkan urutan atau hubungan antara kata-kata. Akurasi tertinggi, 84%, dicapai pada skenario ketujuh, yang menggunakan dataset diacak, penanganan negasi, dan fitur *unigram*. Analisis visual juga mengungkapkan variasi *precision* dan *recall* antara skenario yang berbeda, dengan *precision* positif tertinggi, sebesar 86,6%, tercapai pada pengujian kelima, sementara *precision* negatif tertinggi, yakni 87,9%, diperoleh pada pengujian kedelapan. *Recall* positif tertinggi, sebesar 88,7%, terjadi pada pengujian kedelapan, dan *recall* negatif tertinggi, sebesar 85%, terjadi pada pengujian kelima.

Hasil dan temuan penelitian ini memberikan kontribusi bagi pengembangan model analisis sentimen yang lebih efektif dan akurat dalam memahami opini masyarakat, khususnya dalam bahasa Indonesia. Penelitian ini juga memberikan implikasi bagi praktisi dan pengambil keputusan, yang dapat menggunakan analisis sentimen sebagai salah satu alat untuk mengukur dan meningkatkan kinerja, kualitas, dan kepuasan pelanggan.

Penelitian ini memberikan kontribusi penting bagi analisis sentimen teks, namun tidak luput dari beberapa kekurangan dan tantangan. Data yang di dapat terbatas dalam jumlah dan variasi, sehingga tidak dapat merepresentasikan semua jenis teks atau domain yang ada. Penelitian ini hanya menggunakan metode penanganan negasi yang sederhana, yang belum mampu mengatasi kasus-kasus negasi yang lebih rumit, seperti ironi, sarkasme, atau humor. Penelitian ini hanya memanfaatkan fitur *unigram* dan *bigram*, yang kurang dapat mengungkap makna atau nuansa yang tersirat atau tersembunyi dalam teks.

Untuk itu, penelitian mendatang dapat melakukan beberapa hal berikut untuk meningkatkan kualitas penelitian ini, antara lain: Menggunakan data yang lebih banyak dan beragam, dari berbagai sumber yang berbeda, seperti media sosial, blog, forum, atau ulasan produk. Menggunakan metode penanganan negasi yang lebih maju dan fleksibel, dengan memanfaatkan teknik-teknik seperti *lexicon-based*, *rule-based*, atau *machine learning*. Mengeksplorasi fitur-fitur lain yang dapat memperbaiki performa SVM, seperti *trigram*, *n-gram*, *POS-tag*, atau *sentiwordnet*.

Secara keseluruhan, eksperimen menyoroti pentingnya penanganan negasi dan jenis fitur serta dataset diacak dalam meningkatkan performa SVM

pada analisis sentimen. Pemilihan skenario pengujian juga menjadi faktor kritis, dengan hasil terbaik dicapai pada pengujian ketujuh. Implikasi penelitian ini memberikan wawasan berharga untuk pengembangan model analisis sentimen yang lebih efektif dalam memahami opini masyarakat.

Referensi

- Amrizal, V. (2018). Penerapan Metode Term Frequency Inverse Document Frequency (Tf-Idf) Dan Cosine Similarity Pada Sistem Temu Kembali Informasi Untuk Mengetahui Syarah Hadits Berbasis Web (Studi Kasus: Hadits Shahih Bukhari-Muslim). *Jurnal Teknik Informatika*, 11(2), 149–164. <https://doi.org/10.15408/jti.v11i2.8623>
- Athira Luqyana, W., Cholissodin, I., & Perdana, R. S. (2018). Analisis Sentimen Cyberbullying pada Komentar Instagram dengan Metode Klasifikasi Support Vector Machine. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 2(11), 4704–4713. <http://j-ptiik.ub.ac.id>
- Bhatnagar, S., & Choubey, N. (2021). Making sense of tweets using sentiment analysis on closely related topics. *Social Network Analysis and Mining*, 11(1). <https://doi.org/10.1007/s13278-021-00752-0>
- Costello, F. J., & Lee, K. C. (2020). Exploring the Sentiment Analysis of Electric Vehicles Social Media Data by Using Feature Selection Methods. *Journal of Digital Convergence*, 18(2), 249–259. <https://doi.org/10.14400/JDC.2020.18.2.249>
- Geissdoerfer, M., Pieroni, M. P. P., Pigosso, D. C. A., & Soufani, K. (2020). Circular business models: A review. *Journal of Cleaner Production*, 277(August). <https://doi.org/10.1016/j.jclepro.2020.123741>
- German Association of the Automotive Industry. (2021). *Pkw-Produktion deutscher Hersteller in Deutschland*. <https://www.vda.de/de>
- Handayani, F., & Mustikasari, M. (2020). Sentiment Analysis of Electric Cars Using Recurrent Neural Network Method in Indonesian Tweets. *Jurnal Ilmiah Kursor*, 10(4), 153–158. <https://doi.org/10.21107/kursor.v10i4.233>
- Impressum. (2021). *2020 (Full Year) International: Worldwide Car Sales*. <https://www.best-selling-cars.com/international/2020-full-year-international-worldwide-car-sales/>



- Jefferson, O. A., Jaffe, A., Ashton, D., Warren, B., Koellhofer, D., Dulleck, U., Ballagh, A., Moe, J., Dicuccio, M., Ward, K., Bilder, G., Dolby, K., & Jefferson, R. A. (2018). Erratum: Mapping the global influence of published research on industry and innovation (Nat. Biotechnol., 2018 36, 31–39). *Nature Biotechnology*, 36(8), 772. <https://doi.org/10.1038/NBT0818-772A>
- Mauleón, I. (2021). Aggregated world energy demand projections: Statistical assessment. *Energies*, 14(15). <https://doi.org/10.3390/en14154657>
- Maulidina, M. K. (2020). Analisis Sentimen Komentar Warganet Terhadap Postingan Instagram Menggunakan Metode Naive Bayes Classifier dan TF-IDF. *Naskah Publikasi Universitas Teknologi Yogyakarta*, 1–15.
- Nai, W., Yang, Z., Wei, Y., Sang, J., Wang, J., Wang, Z., & Mo, P. (2022). A Comprehensive Review of Driving Style Evaluation Approaches and Product Designs Applied to Vehicle Usage-Based Insurance. *Sustainability (Switzerland)*, 14(13). <https://doi.org/10.3390/su14137705>
- Nasution, M. R. A., & Hayaty, M. (2019). Perbandingan Akurasi dan Waktu Proses Algoritma K-NN dan SVM dalam Analisis Sentimen Twitter. *Jurnal Informatika*, 6(2), 226–235. <https://doi.org/10.31311/ji.v6i2.5129>
- Olabi, A. G., Wilberforce, T., Sayed, E. T., Elsaid, K., & Abdelkareem, M. A. (2020). Prospects of fuel cell combined heat and power systems. *Energies*, 13(15), 1–20. <https://doi.org/10.3390/en13164104>
- Renas Madya Pradhana. (2021). Analisis Sentimen Publik Terhadap Kebijakan Pemberlakuan Pembatasan Kegiatan Masyarakat Skala Mikro Menggunakan Algoritma Support Vector Machine Studi Kasus Twitter. *Universitas Dinamika*, 10(4), 66.
- Rivki, M., & Bachtiar, A. M. (2017). IMPLEMENTASI ALGORITMA K-NEAREST NEIGHBOR DALAM PENGKLASIFIKASIAN FOLLOWER TWITTER YANG MENGGUNAKAN BAHASA INDONESIA. *Jurnal Sistem Informasi (Journal of Information System)*, 13(1), 1–23.
- Santoso, A., Nugroho, A., & Sunge, A. S. (2022). Analisis Sentimen Tentang Mobil Listrik Dengan Metode Support Vector Machine Dan Feature Selection Particle Swarm Optimization. *Journal of Practical Computer Science*, 2(1), 24–31. <https://doi.org/10.37366/jpcs.v2i1.1084>
- Septiani, R., Citra, I. P. A., & Nugraha, A. S. A. (2019). Perbandingan Metode Supervised Classification dan Unsupervised Classification terhadap Penutup Lahan di Kabupaten Buleleng. *Jurnal Geografi : Media Informasi Pengembangan Dan Profesi Kegeografian*, 16(2), 90–96. <https://doi.org/10.15294/jg.v16i2.19777>
- Supriyati, E., & Iqbal, M. (2018). Pengukuran Similarity Tema Pada Juz 30 Al Qur'an Menggunakan Teks Klasifikasi. *Simetris: Jurnal Teknik Mesin, Elektro Dan Ilmu Komputer*, 9(1), 361–370. <https://doi.org/10.24176/simet.v9i1.1955>
- Vongurai, R. (2020). Factors affecting customer brand preference toward electric vehicle in Bangkok, Thailand. *Journal of Asian Finance, Economics and Business*, 7(8), 383–393. <https://doi.org/10.13106/JAFEB.2020.VOL7.NO8.383>
- Welsby, D., Price, J., Pye, S., & Ekins, P. (2021). Unextractable fossil fuels in a 1.5 °C world. *Nature*, 597(7875), 230–234. <https://doi.org/10.1038/s41586-021-03821-8>

