

BUKU MONOGRIFT

Membangun Model Sentimen
dengan Mengintegrasikan Linguistik
dan Teknologi untuk E-Commerce



Fauziah Hanum, S.Pd., M.Pd
Richi Andrianto, S.Kom., M.Kom
Anita Sri Rejeki Hutagaol, S.Pd., M.Pd
Ibnu Rasyid Munthe, ST., M.Kom

BUKU MONOGRAFT

Membangun Model Sentimen Dengan Mengintegrasikan Linguistik dan Teknologi untuk E-Commerce

Buku Monograf
Membangun Model Sentimen Dengan
Mengintegrasikan Linguistik dan Teknologi untuk
E-Commerce

Fauziah Hanum, S.Pd., M.Pd
Richi Andrianto, S.Kom., M.Kom
Anita Sri Rejeki Hutagaol, S.Pd., M.Pd
Ibnu Rasyid Munthe, S.T., M.Kom



**BUKU MONOGRAF MEMBANGUN MODEL SENTIMEN DENGAN MENINGTEGRASIKAN
LINGUISTIK DAN TEKNOLOGI UNTUK E-COMMERCE**

**Fauziah Hanum, S.Pd., M.Pd
Richi Andrianto, S.Kom., M.Kom
Anita Sri Rejeki Hutagaol, S.Pd., M.Pd
Ibnu Rasyid Munthe, S.T., M.Kom**

Editor :
Sahat Parulian Sitorus

Desain Cover :
Nurhasanah

Sumber :
<https://isbn.jndi.my.id/products/buku-monografit-membangun-model-sentimen-dengan-mengintegrasikan-linguistik-dan-teknologi-untuk-e-commerce>

Tata Letak :
Ida Royani Sitorus

Ukuran :
Jml hal judul 120, Jml hal isi naskah 111, Uk: 17x25 cm

ISBN :
978-643-04-2310-5

Cetakan Pertama :
06 Agustus 2025

Hak Cipta 2025, Pada Penulis
Isi diluar tanggung jawab percetakan

Copyright © 2025 by PT.JNDI
All Right Reserved

Hak cipta dilindungi undang-undang
Dilarang keras menerjemahkan, memfotokopi, atau
memperbanyak sebagian atau seluruh isi buku ini
tanpa izin tertulis dari Penerbit.

PENERBIT PT. JASA NIAGA DIGITAL INDONESIA
Jl. H. Maulana Link. VI. Labuhan Ruku, Talawi, Batu Bara, Sumatera Utara 21254
Telp/Wa : 082361274081
<https://isbn.jndi.my.id>
E-mail:office@jndi.my.id

PRAKATA

Buku monograf ini berjudul "**Membangun Model Sentimen Dengan Mengintegrasikan Linguistik dan Teknologi untuk E-Commerce**". Dalam era digital yang berkembang pesat, e-commerce telah menjadi bagian integral dari kehidupan sehari-hari, di mana ulasan produk dari konsumen memberikan wawasan berharga tentang pengalaman pengguna. Buku ini bertujuan untuk memberikan pemahaman yang komprehensif tentang bagaimana analisis sentimen dapat diterapkan untuk memahami persepsi konsumen terhadap produk dan layanan yang ditawarkan.

Melalui penggabungan pemahaman linguistik dan teknik machine learning, buku ini menyajikan metode analisis yang efisien untuk mengelola dan menganalisis data ulasan produk. Dengan menggunakan teknik ekstraksi fitur seperti TF-IDF dan Word2Vec serta model pembelajaran mesin seperti Support Vector Machine (SVM), buku ini menunjukkan bagaimana perusahaan dapat meningkatkan layanan, merespons umpan balik pelanggan, dan merancang strategi pemasaran yang lebih efektif. Diharapkan, buku ini dapat menjadi panduan praktis bagi peneliti dan praktisi di bidang e-commerce dalam menerapkan analisis sentimen secara efektif.

Rantauprapat, Agustus 2025

Tim Penulis

KATA PENGANTAR

Buku monograf ini, berjudul "**Membangun Model Sentimen Dengan Mengintegrasikan Linguistik dan Teknologi untuk E-Commerce**", hadir sebagai upaya untuk menjembatani kesenjangan antara teori linguistik dan praktik analisis data dalam e-commerce. Dalam era digital saat ini, ulasan produk dari konsumen menjadi sumber informasi yang sangat berharga bagi perusahaan. Oleh karena itu, penting untuk memiliki sistem yang mampu menganalisis sentimen dengan akurat.

Dalam buku ini, pembaca akan diajak untuk memahami bagaimana teknik ekstraksi fitur seperti TF-IDF dan Word2Vec dapat diterapkan dalam analisis sentimen. Selain itu, model pembelajaran mesin seperti Support Vector Machine (SVM) akan dibahas secara mendalam, termasuk teknik optimasi hyperparameter yang dapat meningkatkan akurasi klasifikasi sentimen.

Buku ini ditujukan bagi para peneliti, praktisi, dan profesional di bidang e-commerce yang ingin mengembangkan sistem analisis sentimen yang lebih efektif. Dengan mengintegrasikan teori linguistik dan teknologi mutakhir, diharapkan buku ini dapat memberikan panduan praktis dan solusi untuk tantangan analisis sentimen yang kompleks. Semoga karya ini bermanfaat dan dapat menginspirasi penelitian lebih lanjut dalam bidang analisis sentimen di e-commerce.

Rantauprapat, Agustus 2025

Tim Penulis

DAFTAR ISI

PRAKATA	iv
KATA PENGANTAR	v
BAB 1. Pendahuluan	1
Pentingnya Analisis Sentimen dalam E-Commerce.....	1
Tujuan Buku dan Sasaran Pembaca	1
1.1. Perkembangan Teknologi	2
1.2. Tujuan.....	4
BAB 2. Konsep Dasar Sentimen	7
2.1. Definisi Sentimen	7
2.2. Pentingnya Analisis Sentimen dalam E-Commerce.....	11
2.3. Metode Analisis Sentimen.....	13
BAB 3 Pendekatan Linguistik dalam Analisis Sentimen	15
3.1. Linguistik dalam Analisis Teks.....	15
3.2. Pengaruh Variasi Bahasa dalam Sentimen.....	21
3.3. Teknologi NLP dan Perannya dalam Analisis Sentimen	26
BAB 4. Support Vector Machine (SVM) untuk Klasifikasi Sentimen	29
4.1. Teori Dasar SVM.....	29
4.2. Penerapan SVM dalam Klasifikasi Sentimen	31
4.3. Implementasi SVM dalam Model Hybrid.....	33
BAB 5. Teknik Ekstraksi Fitur dalam Analisis Sentimen.....	36
5.1. TF-IDF Representasi Kata Berdasarkan Frekuensi	36
5.2. Word2Vec Representasi Semantik Kata	40
5.3. Perbandingan TF-IDF dan Word2Vec	44
BAB 6. Preprocessing Data Teks untuk Analisis Sentimen.....	51

6.1. Teknik Preprocessing dalam NLP.....	51
6.2. Pengolahan Teks Bahasa Indonesia.....	56
BAB 7. Hyperparameter Tuning dalam Pengoptimalan Model ..	63
7.1. Definisi Hyperparameter Tuning.....	63
7.2. Metode Hyperparameter Tuning.....	65
7.3. Penerapan Hyperparameter Tuning pada Model SVM	75
BAB 8. Evaluasi Model Sentimen.....	82
8.1. Metrik Evaluasi dalam Klasifikasi Sentimen.....	82
8.2. Hasil Pengujian Model	87
8.3. Diskusi Hasil.....	93
BAB 9. Implikasi Praktis dalam E-Commerce.....	98
9.1. Penggunaan Analisis Sentimen untuk Pengambilan Keputusan	98
9.2. Penerapan Model Sentimen dalam Sistem E-Commerce ...	100
9.3. Manfaat Model Hybrid untuk Perusahaan E-Commerce	101
BAB 10. Kesimpulan dan Rekomendasi.....	104
10.1. Kesimpulan	104
10.2. Rekomendasi untuk Penelitian Selanjutnya.....	104
10.3. Implikasi Praktis.....	105
DAFTAR PUSTAKA.....	106

BAB 1

Pendahuluan

Pentingnya Analisis Sentimen dalam E-Commerce

Dalam era digital yang berkembang pesat, e-commerce telah menjadi pilar utama ekonomi global, dengan ulasan produk konsumen sebagai fitur kunci dalam platform e-commerce. Ulasan ini memberikan informasi berharga tentang pengalaman pembeli dengan produk tertentu, yang sering kali menjadi referensi utama bagi calon pembeli dalam keputusan mereka. Oleh karena itu, penting memiliki sistem yang dapat menganalisis sentimen dalam ulasan secara akurat. Analisis sentimen digunakan untuk menentukan apakah teks mengandung sentimen positif, negatif, atau netral, memberikan wawasan tentang persepsi konsumen terhadap produk atau layanan. Dengan memahami sentimen ini, perusahaan dapat memperbaiki produk, meningkatkan pelayanan, dan merespons masalah dengan lebih cepat. Selain itu, analisis sentimen juga berperan penting dalam pengelolaan reputasi merek dan pengambilan keputusan berbasis data. Seiring dengan peningkatan jumlah ulasan, perusahaan memerlukan teknik efisien untuk mengelola dan menganalisis data ini agar dapat merespons sentimen konsumen dengan tepat.

Tujuan Buku dan Sasaran Pembaca

E-commerce kini menjadi pilar penting dalam ekonomi global, dengan ulasan produk sebagai elemen krusial dalam platform ini. Ulasan konsumen sering menjadi referensi utama bagi pembeli potensial. Oleh karena itu, analisis sentimen yang dapat menentukan apakah ulasan tersebut positif, negatif, atau netral sangat diperlukan. Analisis ini membantu perusahaan memahami persepsi konsumen, memperbaiki produk dan layanan, serta merancang strategi pemasaran yang lebih efektif. Seiring dengan jumlah ulasan yang terus berkembang,

perusahaan membutuhkan sistem efisien untuk menganalisis sentimen guna merespons secara cepat dan tepat terhadap opini konsumen .

1.1. Teknologi Informasi

Perkembangan teknologi informasi (TI) telah memberikan dampak signifikan pada berbagai sektor, termasuk perdagangan. Salah satu inovasi terpenting adalah e-commerce, yang memungkinkan transaksi jual beli barang dan jasa melalui internet, mengurangi kebutuhan interaksi langsung antara konsumen dan penjual. Platform-platform seperti Amazon, eBay, Tokopedia, dan Bukalapak telah memainkan peran utama dalam mempermudah akses bagi konsumen di seluruh dunia (Bordoloi & Biswas, 2023). Kemajuan dalam teknologi internet, sistem pembayaran digital, dan logistik mendukung kemudahan bertransaksi secara online, yang memberikan kenyamanan bagi konsumen dan peluang bagi bisnis untuk memperluas pasar dengan biaya lebih efisien. Namun, seiring dengan pertumbuhannya, e-commerce menghadapi tantangan besar dalam mengelola data yang berkembang pesat, terutama ulasan produk yang berfungsi sebagai sumber penting informasi konsumen (Rezapour, 2020). Oleh karena itu, penting untuk mengembangkan sistem analisis yang efektif guna mengekstrak wawasan berharga dari data yang tidak terstruktur ini.

Pentingnya Analisis Sentimen dalam Memahami Perilaku Konsumen Melalui Ulasan Produk

Ulasan produk yang ditulis oleh konsumen di platform e-commerce merupakan sumber informasi yang sangat berharga. Ulasan ini mencerminkan pengalaman pengguna terhadap produk atau layanan yang mereka beli, memberikan umpan balik yang berguna bagi perusahaan untuk mengidentifikasi kekuatan dan kelemahan produk mereka. Ulasan produk sering menjadi referensi utama bagi calon pembeli dalam menentukan keputusan pembelian. Melalui analisis

sentimen, perusahaan dapat mengetahui apakah ulasan tersebut mengandung sentimen positif, negatif, atau netral, yang memberikan gambaran yang jelas mengenai persepsi konsumen terhadap produk atau layanan yang ditawarkan (Ardhani et al., 2021). Dengan pemahaman ini, perusahaan dapat mengidentifikasi aspek produk yang perlu diperbaiki atau menonjolkan kelebihan produk yang diapresiasi konsumen. Selain itu, analisis sentimen juga berguna untuk memantau reputasi merek secara real-time. Misalnya, jika banyak ulasan negatif terkait pengiriman atau kualitas produk, perusahaan dapat segera merespons dan melakukan perbaikan, meningkatkan kualitas layanan, dan menjaga kepuasan pelanggan. Analisis sentimen juga mendukung perencanaan strategi pemasaran yang lebih efektif, karena memberikan wawasan tentang apa yang disukai dan tidak disukai oleh pelanggan, memungkinkan perusahaan merancang kampanye yang lebih relevan dan tepat sasaran.

Tantangan dalam Menganalisis Sentimen Keragaman Bahasa, Ambiguitas, dan sindiran dalam teks ulasan

Meskipun analisis sentimen memiliki banyak manfaat, ada sejumlah tantangan yang perlu dihadapi, terutama terkait dengan keragaman bahasa, ambiguitas, dan konteks dalam ulasan produk. Salah satu tantangan terbesar adalah keragaman bahasa yang digunakan oleh konsumen di platform e-commerce. Ulasan produk bisa ditulis dengan berbagai gaya bahasa, termasuk slang, bahasa sehari-hari, atau dialek regional, yang meningkatkan kompleksitas analisis sentimen. Sistem analisis harus mampu memahami makna kata yang digunakan, yang bisa sangat bervariasi antar individu atau kelompok (Noor et al., 2022). Ambiguitas bahasa juga menjadi tantangan, di mana kalimat bisa mengandung makna yang berbeda tergantung konteksnya. Misalnya, kalimat seperti "Produk ini sangat buruk, meskipun harganya sangat murah" mengandung sentimen negatif meskipun ada kata "murah" yang biasa dianggap positif. Model sentimen harus mempertimbangkan keseluruhan kalimat dan konteksnya, menggunakan teknik seperti Word2Vec yang dapat menangkap hubungan semantik antar kata

(Mikolov et al., 2013). Selain itu, sindiran dan ironi dalam teks juga bisa membingungkan Model. Teknik ekstraksi fitur seperti TF-IDF dan Word2Vec diperlukan untuk menangani tantangan ini, karena TF-IDF memberikan bobot pada kata-kata penting, sementara Word2Vec memahami hubungan antar kata berdasarkan konteks (Dong et al., 2020). Optimasi hyperparameter menggunakan metode seperti GridSearchCV atau Optuna juga penting untuk meningkatkan akurasi model.

1.2. Tujuan

Meningkatkan akurasi analisis sentimen menggunakan model hybrid.

Analisis sentimen pada ulasan produk e-commerce sangat penting untuk memberikan wawasan tentang persepsi konsumen terhadap suatu produk atau layanan. Namun, dengan meningkatnya volume data ulasan, tantangan utama yang dihadapi adalah memastikan Model sentimen dapat bekerja dengan tingkat akurasi yang tinggi. Untuk itu, pengembangan model hybrid yang menggabungkan berbagai teknik ekstraksi fitur dan optimasi hyperparameter menjadi kunci untuk meningkatkan akurasi model dalam menghadapi kompleksitas bahasa yang beragam (Rezapour, 2020). Model hybrid yang digunakan dalam penelitian ini menggabungkan teknik TF-IDF dan Word2Vec sebagai metode ekstraksi fitur, serta mengoptimalkan model melalui pengaturan hyperparameter menggunakan teknik seperti GridSearchCV, RandomizedSearchCV, dan Optuna. Dengan pendekatan ini, diharapkan model dapat lebih efektif dalam menangkap informasi mendalam dari ulasan produk dan meningkatkan performa analisis sentimen secara signifikan. Kombinasi teknik ini memungkinkan model untuk tidak hanya memperhitungkan frekuensi kata-kata, tetapi juga memahami hubungan semantik antar kata dalam konteks kalimat, yang penting untuk mengatasi keragaman bahasa dan ambiguitas dalam ulasan (Ardhani et al., 2021; Rezapour, 2020)..

Penggunaan teknik ekstraksi fitur seperti TF-IDF dan Word2Vec untuk memaksimalkan hasil analisis.

TF-IDF (Term Frequency-Inverse Document Frequency) adalah metode yang digunakan untuk memberikan bobot pada kata-kata dalam teks berdasarkan pentingnya kata tersebut dalam konteks dokumen dibandingkan dengan seluruh koleksi dokumen. TF-IDF efektif untuk mengurangi pengaruh kata-kata yang tidak relevan, seperti kata hubung dan kata yang sering muncul, serta lebih menyoroti kata-kata yang memiliki makna lebih dalam dalam konteks sentimen. Teknik ini sangat berguna dalam pengolahan data teks dalam skala besar (Su, 2022). Meskipun demikian, TF-IDF memiliki keterbatasan dalam menangkap hubungan semantik antar kata, yang sangat penting dalam analisis sentimen yang melibatkan konteks yang lebih luas. Untuk mengatasi kekurangan ini, Word2Vec digunakan sebagai teknik ekstraksi fitur kedua. Word2Vec mengubah kata-kata menjadi vektor berdimensi tinggi yang dapat menangkap makna semantik kata berdasarkan konteks penggunaannya dalam kalimat. Teknik ini memungkinkan model untuk lebih memahami hubungan antar kata dalam teks, yang sangat berguna dalam memperbaiki analisis sentimen, terutama ketika teks mengandung makna yang lebih kompleks atau ambiguitas. Dengan memadukan kedua teknik ini, Model sentimen dapat lebih efektif dalam memahami dan mengklasifikasikan sentimen dalam ulasan produk (Rezki et al., 2023).

Optimasi model dengan pendekatan hyperparameter tuning untuk meningkatkan performa.

Setelah ekstraksi fitur dilakukan, langkah penting berikutnya adalah mengoptimalkan model untuk memastikan akurasi yang tinggi. Salah satu teknik optimasi yang digunakan adalah hyperparameter tuning. Dalam penelitian ini, optimasi dilakukan menggunakan tiga metode yang berbeda: GridSearchCV, RandomizedSearchCV, dan Optuna.

GridSearchCV mencoba semua kombinasi hyperparameter yang mungkin untuk menemukan kombinasi terbaik yang memaksimalkan akurasi model. Sebaliknya, RandomizedSearchCV mencoba kombinasi acak yang lebih efisien dalam hal waktu pencarian parameter optimal. Namun, Optuna menawarkan metode optimasi yang lebih efisien dengan pendekatan trial-and-error yang adaptif, di mana algoritma memilih kombinasi parameter lebih menjanjikan berdasarkan hasil percobaan sebelumnya (Nugraha, 2022). Penggunaan Optuna dalam penelitian ini menunjukkan peningkatan signifikan dalam akurasi model dibandingkan dengan GridSearchCV dan RandomizedSearchCV. Berdasarkan eksperimen yang dilakukan, model yang dioptimalkan dengan Optuna mencapai akurasi hingga 87%, sementara GridSearchCV dan RandomizedSearchCV masing-masing hanya memberikan akurasi 85% dan 83% (Ardhani et al., 2021). Hasil ini menunjukkan bahwa Optuna dapat menjadi pilihan yang lebih baik dalam optimasi Model sentimen, dengan kemampuan untuk meningkatkan akurasi secara lebih efektif.

BAB 2

Konsep Dasar Sentimen

2.1. Definisi Sentimen

Pengertian Sentimen dalam Linguistik

Sentimen dalam linguistik merujuk pada sikap atau perasaan yang diekspresikan oleh penulis atau pembicara terhadap objek, peristiwa, atau fenomena tertentu. Dalam ilmu linguistik, sentimen ini umumnya dikategorikan menjadi tiga jenis utama: positif, negatif, dan netral. Definisi sentimen ini penting dalam analisis sentimen karena memungkinkan peneliti untuk mengevaluasi emosi, opini, atau perasaan yang terkandung dalam teks atau ujaran (Salsabila et al., 2023; Bordoloi & Biswas, 2023). Dalam konteks digital, terutama dalam analisis ulasan produk e-commerce, sentimen menjadi fokus utama untuk mengevaluasi persepsi konsumen terhadap produk atau layanan. Analisis sentimen tidak hanya melihat kata-kata yang digunakan, tetapi juga konteks tempat kata tersebut muncul. Sebagai contoh, kalimat seperti "produk ini sangat bagus" mengindikasikan sentimen positif, sementara "produk ini sangat buruk" menunjukkan sentimen negatif. Namun, tantangan muncul pada kalimat yang ambigu atau menggunakan bahasa tidak langsung, seperti ironi atau sindiran, yang membutuhkan kemampuan sistem analisis sentimen untuk memahami nuansa dan konteks lebih dalam (Jollyta et al., 2023; Ardhani et al., 2021). Dalam e-commerce, pemahaman terhadap sentimen sangat penting karena sentimen positif menunjukkan kepuasan pelanggan, sementara sentimen negatif bisa menandakan masalah yang mempengaruhi reputasi penjual atau produk. Teknik analisis sentimen membantu perusahaan memahami kebutuhan dan preferensi konsumen untuk membuat keputusan yang lebih baik (Rezapour, 2020).

Klasifikasi Sentimen Positif, Negatif, dan Netral

Klasifikasi sentimen merujuk pada proses pengelompokan opini atau perasaan dalam teks ke dalam kategori yang telah ditentukan. Dalam analisis sentimen, umumnya terdapat tiga kategori utama, yaitu positif, negatif, dan netral. Masing-masing kategori ini mewakili perasaan yang berbeda yang terkandung dalam teks atau ulasan.

1. Sentimen Positif

Sentimen positif merujuk pada perasaan atau opini yang menunjukkan kepuasan atau dukungan terhadap objek atau fenomena tertentu. Dalam analisis sentimen ulasan produk e-commerce, sentimen positif biasanya ditemukan dalam kalimat yang memuji kualitas produk, layanan pelanggan, atau pengalaman berbelanja secara keseluruhan. Sebagai contoh, dalam ulasan seperti "produk ini sangat memuaskan, sangat direkomendasikan," dapat dikategorikan sebagai sentimen positif. Analisis sentimen dalam konteks ini bertujuan untuk mengidentifikasi elemen-elemen positif yang dapat membantu meningkatkan reputasi dan menarik lebih banyak konsumen.

2. Sentimen Negatif

Sentimen negatif berhubungan dengan ketidakpuasan atau keluhan terhadap suatu produk atau layanan. Dalam ulasan produk, sentimen negatif bisa berupa kritik terhadap kualitas produk, masalah pengiriman, atau ketidakpuasan terhadap harga. Misalnya, ulasan seperti "produk ini tidak sesuai dengan harapan saya, sangat mengecewakan" jelas menunjukkan sentimen negatif. Analisis sentimen untuk kategori ini membantu perusahaan untuk mengenali kelemahan mereka dan melakukan perbaikan dalam produk atau layanan yang ditawarkan. Dalam penelitian ini, model klasifikasi sentimen seperti Support Vector Machine (SVM) digunakan untuk membedakan sentimen negatif dari positif berdasarkan fitur teks yang diekstraksi dengan teknik seperti TF-IDF dan Word2Vec.

3. Sentimen Netral

Sentimen netral merujuk pada teks yang tidak secara jelas menunjukkan perasaan positif atau negatif terhadap objek yang dimaksud. Biasanya, kalimat ini bersifat informatif atau deskriptif tanpa adanya opini yang kuat. Contoh kalimat yang netral adalah "produk ini dikirim dengan menggunakan layanan standar." Meskipun ulasan tersebut memberikan informasi tentang produk, tidak ada pernyataan yang mengindikasikan kepuasan atau ketidakpuasan. Dalam beberapa kasus, analisis sentimen harus dapat membedakan antara sentimen positif/negatif dan netral, yang dapat mempengaruhi rekomendasi dan keputusan yang diambil oleh perusahaan.

Implikasi Analisis Sentimen dalam E-Commerce

Dalam e-commerce, analisis sentimen memainkan peran yang sangat penting dalam memahami pengalaman dan kepuasan pelanggan. Sebagai platform yang bergantung pada ulasan produk dari konsumen, perusahaan dapat memanfaatkan hasil analisis sentimen untuk meningkatkan layanan dan produk mereka. Berikut ini adalah beberapa implikasi analisis sentimen dalam e-commerce berdasarkan penelitian yang telah dilakukan.

1. Evaluasi Persepsi Konsumen terhadap Produk

Ulasan produk di platform e-commerce sering kali menjadi referensi utama bagi calon pembeli dalam mengambil keputusan. Dengan melakukan analisis sentimen, perusahaan dapat mengidentifikasi apakah sebagian besar ulasan mengindikasikan kepuasan atau ketidakpuasan terhadap produk mereka. Sebagai contoh, hasil penelitian ini menunjukkan bahwa model SVM yang dioptimasi dengan teknik seperti Optuna dapat meningkatkan akurasi dalam menganalisis sentimen dalam ulasan produk. Dengan pemahaman yang lebih baik mengenai sentimen

konsumen, perusahaan dapat melakukan perbaikan atau penyesuaian pada produk yang kurang disukai.

2. Pengelolaan Reputasi Merek

Reputasi merek sangat dipengaruhi oleh persepsi konsumen yang terwakili dalam ulasan produk. Sentimen negatif yang berulang dapat merusak reputasi perusahaan, sementara sentimen positif dapat memperkuat citra positif perusahaan. Dengan adanya sistem analisis sentimen otomatis, perusahaan dapat dengan cepat merespons masalah yang ditemukan dalam ulasan negatif, seperti keluhan tentang kualitas produk atau layanan. Ini memberikan perusahaan kesempatan untuk meningkatkan reputasi mereka dengan mengambil langkah perbaikan yang tepat.

3. Peningkatan Pengalaman Pelanggan

Dengan menggunakan analisis sentimen, perusahaan dapat memperoleh wawasan berharga tentang preferensi konsumen. Misalnya, jika banyak ulasan yang menyatakan bahwa pelanggan puas dengan kualitas pengemasan, perusahaan dapat lebih menekankan kualitas pengemasan dalam strategi pemasaran mereka. Sebaliknya, jika banyak keluhan terkait pengiriman yang lambat, perusahaan dapat melakukan perbaikan dalam sistem logistik mereka. Penelitian ini menggunakan teknik ekstraksi fitur seperti TF-IDF dan Word2Vec untuk meningkatkan kemampuan model dalam memahami sentimen dalam konteks yang lebih luas.

4. Strategi Pemasaran dan Pengembangan Produk

Berdasarkan hasil analisis sentimen, perusahaan dapat merancang strategi pemasaran yang lebih efektif. Jika analisis menunjukkan bahwa pelanggan cenderung lebih menghargai produk dengan fitur tertentu, perusahaan dapat memfokuskan iklan dan promosi pada fitur tersebut. Selain itu, analisis sentimen dapat memberikan wawasan tentang produk atau fitur yang perlu diperbaiki atau dikembangkan lebih lanjut, membantu perusahaan dalam pengembangan produk yang lebih sesuai dengan kebutuhan pelanggan.

5. Pengambilan Keputusan yang Lebih Tepat

Dengan analisis sentimen, pengambilan keputusan di perusahaan menjadi lebih berbasis data. Hal ini memungkinkan perusahaan untuk membuat keputusan yang lebih tepat terkait dengan perbaikan produk, pengembangan layanan, dan strategi pemasaran. Model-model yang dioptimasi seperti yang dijelaskan dalam penelitian ini, dapat memberikan hasil yang lebih akurat dan efisien dalam mengklasifikasikan sentimen pelanggan.

2.2. Pentingnya Analisis Sentimen dalam E-Commerce

Sentimen dalam ulasan produk sebagai indikator kualitas produk.

Ulasan produk di platform e-commerce berperan krusial dalam membantu konsumen membuat keputusan pembelian sekaligus memberikan perusahaan wawasan tentang kualitas produk mereka. Dalam dunia e-commerce yang berkembang pesat, ulasan konsumen menjadi cerminan dari kualitas produk tersebut. Analisis sentimen, yang mengidentifikasi apakah ulasan tersebut positif, negatif, atau netral, sangat penting untuk menilai persepsi konsumen terhadap produk yang mereka beli. Teknik pengolahan bahasa alami (Natural Language Processing/NLP) seperti tokenisasi, penghapusan stopwords, dan stemming digunakan untuk memproses data teks agar dapat dipahami komputer (Han et al., 2020). Selain itu, teknik ekstraksi fitur seperti TF-IDF dan Word2Vec memainkan peran vital dalam mengoptimalkan model klasifikasi sentimen, seperti yang dibahas oleh Rezapour (2020) dan Ardhani et al. (2021). Penggunaan Support Vector Machine (SVM) sebagai algoritma pembelajaran mesin terbukti efektif dalam meningkatkan akurasi klasifikasi sentimen pada ulasan produk. Studi menunjukkan bahwa SVM dapat menghasilkan klasifikasi yang lebih baik, terutama ketika dioptimasi dengan teknik Word2Vec, yang memungkinkan model menangkap hubungan semantik antar kata dalam kalimat. Sentimen

positif mencerminkan kepuasan konsumen, sementara sentimen negatif menunjukkan ketidakpuasan atau masalah kualitas produk, menjadi indikator kualitas yang sangat berharga (Gandhi et al., 2023). Dengan mengoptimalkan SVM dan fitur ekstraksi seperti TF-IDF dan Word2Vec, perusahaan dapat lebih efektif menilai kualitas produk dan meningkatkan kepuasan pelanggan.

Peran analisis sentimen dalam pengambilan keputusan perusahaan e-commerce.

Pengambilan keputusan dalam perusahaan e-commerce semakin bergantung pada data untuk memahami perilaku konsumen dan mengelola kualitas produk dengan lebih baik. Salah satu alat yang sangat berguna adalah analisis sentimen pada ulasan produk, yang membantu perusahaan membuat keputusan berbasis data. Menurut Noor et al. (2022), analisis sentimen dapat memberikan wawasan lebih dalam tentang persepsi konsumen terhadap produk, yang berguna untuk merancang strategi pemasaran yang lebih efektif dan mengelola hubungan dengan pelanggan. Melalui analisis ini, perusahaan dapat mengidentifikasi produk yang perlu diperbaiki, yang perlu dipromosikan lebih intensif, serta aspek layanan atau pengiriman yang perlu diperbaiki (Setyawan et al., 2023). Penggunaan SVM dan teknik pembelajaran mesin lainnya, seperti Deep Learning, memungkinkan perusahaan menangani data ulasan dalam jumlah besar secara efisien dan akurat. Penelitian oleh Jollyta et al. (2023) dan Rezki et al. (2023) menunjukkan bahwa teknik ekstraksi fitur seperti Word2Vec dapat menangkap konteks lebih dalam dalam ulasan produk, meningkatkan akurasi prediksi sentimen. Dalam penelitian ini, optimasi dengan Optuna terbukti lebih efisien dibandingkan GridSearchCV dan RandomizedSearchCV, menghasilkan akurasi yang lebih tinggi dalam klasifikasi sentimen (Su, 2022). Dengan analisis sentimen yang lebih akurat, perusahaan dapat membuat keputusan yang lebih tepat terkait pengelolaan produk, layanan pelanggan, dan pemasaran..

2.3. Metode Analisis Sentimen

Pendekatan Berbasis Leksikon.

Pendekatan berbasis leksikon adalah metode analisis sentimen yang menggunakan daftar kata yang sudah dikelompokkan dan diberi label sentimen, seperti positif, negatif, atau netral. Dalam pendekatan ini, kata-kata yang ditemukan dalam teks akan dicocokkan dengan leksikon untuk menentukan sentimen secara keseluruhan. Keuntungan utama dari metode ini adalah kesederhanaannya dan kemudahan implementasinya, karena hanya memerlukan pencocokan kata tanpa perlu pelatihan model yang kompleks. Sebagai contoh, penelitian oleh Ardhani et al. (2021) menunjukkan bahwa pendekatan ini efektif untuk mengklasifikasikan ulasan produk e-commerce berdasarkan sentimen, menghasilkan analisis yang cepat meskipun dengan tingkat akurasi terbatas pada kalimat-kalimat yang sederhana dan jelas. Namun, pendekatan berbasis leksikon memiliki keterbatasan yang signifikan. Metode ini kesulitan dalam menangani kalimat yang mengandung ironi atau sindiran, di mana makna tidak dapat ditentukan hanya berdasarkan kata-kata yang muncul. Misalnya, dalam kalimat "Produk ini bagus sekali, tetapi harganya sangat mahal," kata "bagus" akan diklasifikasikan sebagai sentimen positif, padahal keseluruhan sentimen bisa saja negatif. Selain itu, efektivitas metode ini sangat bergantung pada kualitas dan cakupan leksikon yang digunakan. Leksikon yang kurang lengkap atau tidak sesuai dengan nuansa bahasa yang digunakan konsumen dapat menghasilkan analisis yang tidak akurat (Nafis & Awang, 2021).

Pendekatan Berbasis Machine Learning

Pendekatan berbasis machine learning lebih kompleks dan efisien dalam menangani analisis sentimen yang mendalam dan kontekstual. Pada pendekatan ini, model dilatih menggunakan dataset yang telah diberi label dengan kategori sentimen positif atau negatif. Algoritma

pembelajaran mesin kemudian digunakan untuk mengidentifikasi pola dalam data teks dan mengklasifikasikan teks berdasarkan pola tersebut. Salah satu metode machine learning yang banyak digunakan adalah Support Vector Machine (SVM), yang terbukti efektif dalam klasifikasi teks dengan dimensi tinggi, seperti yang dibahas dalam penelitian oleh Ardhani et al. (2021). Penelitian tersebut menunjukkan bahwa optimasi model SVM menggunakan teknik ekstraksi fitur seperti TF-IDF dan Word2Vec dapat meningkatkan akurasi analisis sentimen hingga 87%, jauh lebih tinggi dibandingkan model dasar yang hanya mencapai 79,5%. Kelebihan utama dari pendekatan ini adalah kemampuannya untuk menangkap hubungan antar kata dalam konteks lebih luas, serta kemampuan model untuk beradaptasi dengan data teks yang lebih kompleks. SVM yang digabungkan dengan Word2Vec, misalnya, dapat memahami makna semantik antar kata dalam kalimat, yang memungkinkan analisis sentimen lebih halus. Namun, meskipun lebih canggih, pendekatan ini memerlukan dataset berlabel besar dan sumber daya komputasi yang lebih besar, serta tantangan dalam interpretabilitas model, yang sulit dijelaskan karena SVM sering kali dianggap sebagai "black-box" (Rezapour, 2020).

BAB 3

Pendekatan Linguistik dalam Analisis Sentimen

3.1. Linguistik dalam Analisis Teks

Morfologi, sintaksis, dan semantik dalam analisis sentimen.

Morfologi adalah cabang linguistik yang mempelajari struktur kata, termasuk bagaimana kata dibentuk dari unit terkecil yang disebut morfem. Dalam konteks analisis sentimen, morfologi memiliki peran penting dalam menangani variasi bentuk kata, terutama dalam bahasa yang memiliki banyak afiks atau perubahan bentuk kata, seperti bahasa Indonesia. Sebagai contoh, kata "berbahagia", "kebahagiaan", dan "bahagia" memiliki akar kata yang sama dan diharapkan mengandung sentimen positif meskipun ditulis dalam bentuk yang berbeda. Untuk meningkatkan akurasi analisis sentimen, teknik seperti stemming atau lemmatization digunakan untuk mengembalikan kata-kata ke bentuk dasar mereka. Proses stemming ini telah diterapkan dalam penelitian sebelumnya, yang menunjukkan bahwa penggunaan algoritma Sastrawi Stemmer pada dataset ulasan produk e-commerce dapat menyederhanakan kata-kata dan meningkatkan performa Model sentimen. Misalnya, kata "berbahagia" atau "kebahagiaan" akan diproses menjadi "bahagia", memungkinkan model untuk memperlakukan bentuk kata yang memiliki makna yang sama secara konsisten. Namun, meskipun teknik morfologi seperti stemming dapat meningkatkan efisiensi, ada keterbatasan, seperti potensi kesalahan dalam menggabungkan kata dengan makna yang berbeda meskipun memiliki akar kata yang sama, seperti "berlari" dan "berjalan". Oleh karena itu, teknik morfologi perlu digunakan dengan hati-hati dan sering kali harus dipadukan dengan teknik lain yang mempertimbangkan konteks kalimat..

Sintaksis dalam Analisis Sentimen

Sintaksis berfokus pada struktur kalimat dan bagaimana kata-kata disusun untuk membentuk makna dalam suatu teks. Dalam analisis sentimen, sintaksis memainkan peran penting karena perubahan struktur kalimat dapat mengubah makna sentimen secara signifikan. Sebagai contoh, kalimat "Produk ini sangat bagus" mengandung sentimen positif, sementara kalimat "Produk ini tidak begitu bagus" memiliki sentimen negatif, meskipun kata "bagus" muncul dalam kedua kalimat tersebut. Oleh karena itu, analisis sintaksis menjadi penting untuk memastikan model dapat memahami struktur gramatikal dan peran setiap kata dalam kalimat (Han et al., 2020). Dependency parsing adalah teknik sintaksis yang digunakan untuk memahami hubungan antar kata dalam kalimat. Dengan teknik ini, model dapat mengidentifikasi hubungan antara subjek, predikat, objek, dan keterangan dalam kalimat. Penelitian yang telah dilakukan menunjukkan bahwa penerapan dependency parsing dalam analisis sentimen dapat membantu model untuk menafsirkan sentimen dengan lebih tepat. Misalnya, dalam kalimat "Meskipun harganya mahal, produk ini sangat bagus," dependency parsing memungkinkan model untuk mengenali bahwa sentimen "mahal" tidak mempengaruhi sentimen keseluruhan karena klausa utama yang memberi makna positif adalah "produk ini sangat bagus." Namun, teknik ini juga memiliki tantangan, terutama ketika bekerja dengan kalimat panjang atau tidak terstruktur yang bisa menyulitkan model dalam melakukan parsing yang akurat (Setyawan et al., 2023).

Semantik dalam Analisis Sentimen

Pemahaman semantik sangat penting dalam analisis sentimen karena sentimen dalam teks tidak hanya bergantung pada kata-kata yang digunakan, tetapi juga pada hubungan antar kata dalam kalimat. Sebagai contoh, kalimat "Meskipun harga mahal, produk ini sangat berguna" memiliki sentimen positif meskipun terdapat kata "mahal" yang biasanya dikaitkan dengan konotasi negatif. Model yang dapat menangkap hubungan semantik antara kata "mahal" dan "berguna" akan mampu

mengklasifikasikan kalimat ini dengan lebih akurat. Teknik-teknik seperti Word2Vec dan TF-IDF sering digunakan untuk menangkap hubungan semantik antar kata. Word2Vec mengubah kata-kata dalam teks menjadi vektor berdimensi tinggi yang mewakili makna semantik berdasarkan konteks penggunaannya. Dalam penelitian yang telah dilakukan, penggunaan Word2Vec untuk ekstraksi fitur terbukti meningkatkan akurasi analisis sentimen pada dataset ulasan produk e-commerce, karena model dapat menangkap nuansa semantik yang lebih dalam dibandingkan metode berbasis frekuensi kata seperti TF-IDF. Dengan Word2Vec, model dapat memahami bahwa kata-kata seperti "raja" dan "ratu" memiliki hubungan semantik yang erat meskipun berbeda dalam arti. Namun, meskipun efektif, penggunaan teknik semantik ini memiliki tantangan. Word2Vec memerlukan data pelatihan yang sangat besar dan seringkali kesulitan dalam menangani teks yang ambigu atau mengandung ironi, seperti kalimat sindiran "Produk ini luar biasa, meskipun tidak pernah berfungsi dengan baik" (Rezapour, 2020).

Integrasi Morfologi, Sintaksis, dan Semantik dalam Analisis Sentimen

Meskipun morfologi, sintaksis, dan semantik memiliki peran penting dalam analisis sentimen, integrasi ketiganya sangat diperlukan untuk menghasilkan analisis yang lebih akurat dan kontekstual. Penelitian menunjukkan bahwa model Support Vector Machine (SVM) yang digabungkan dengan teknik ekstraksi fitur seperti Word2Vec dan optimasi menggunakan Optuna dapat meningkatkan akurasi klasifikasi sentimen. Model ini menggabungkan ketiga aspek linguistik—morfologi, sintaksis, dan semantik—untuk memberikan hasil yang lebih holistik dan efektif dalam menangani teks yang kompleks. Sebagai contoh, dengan mengintegrasikan teknik-teknik ini, model dapat memahami variasi kata (morfologi), struktur kalimat (sintaksis), serta makna kata dalam konteksnya (semantik), yang sangat penting dalam menganalisis ulasan produk. Selain itu, penerapan model hybrid yang menggabungkan Convolutional Neural Networks (CNN) untuk mengekstraksi fitur lokal dengan Bidirectional Long Short-Term Memory (BiLSTM) untuk

menangkap ketergantungan jangka panjang semakin memperkuat analisis yang lebih kontekstual. Model ini dapat menangani ulasan produk yang panjang dan tidak terstruktur dengan lebih efektif, karena mempertimbangkan ketiga aspek linguistik dalam satu sistem. Dengan demikian, integrasi morfologi, sintaksis, dan semantik memungkinkan model untuk lebih baik memahami hubungan antar kata, struktur kalimat, dan konteks secara lebih akurat, yang pada gilirannya meningkatkan akurasi dalam klasifikasi sentimen (Ardhani et al., 2021).

Ambiguitas bahasa, ironi, dan sindiran dalam teks ulasan.

Ambiguitas bahasa terjadi ketika suatu kata atau kalimat memiliki lebih dari satu makna tergantung pada konteks penggunaannya. Dalam analisis sentimen, ambiguitas ini menjadi tantangan besar karena model mungkin kesulitan membedakan sentimen positif atau negatif ketika makna kata tidak jelas. Sebagai contoh, kata “bagus” dalam kalimat “Produk ini sangat bagus” mengandung sentimen positif, tetapi dalam kalimat “Produk ini bagus, namun terlalu mahal,” kata yang sama bisa dianggap negatif karena adanya kontras antara kualitas dan harga. Ambiguitas semacam ini memengaruhi cara teks dipahami oleh Model sentimen. Penelitian yang dilakukan menunjukkan bahwa model berbasis Support Vector Machine (SVM) yang diterapkan pada data ulasan produk sering kesulitan dalam menangani ambiguitas tersebut. Misalnya, kata “baik” bisa merujuk pada kualitas produk atau pengalaman pengguna, tergantung konteks kalimatnya. Model yang hanya mengandalkan pencocokan kata tunggal tanpa memperhatikan konteks bisa menghasilkan sentimen yang salah. Untuk mengatasi tantangan ini, penelitian tersebut menerapkan model berbasis Word2Vec dan TF-IDF. Word2Vec menghasilkan representasi kata dalam bentuk vektor yang lebih kuat, dengan mempertimbangkan konteks penggunaan kata dalam kalimat. Meskipun demikian, tantangan tetap ada, terutama jika data pelatihan tidak mencakup konteks yang cukup beragam, yang dapat mempengaruhi akurasi model dalam menangkap ambiguitas tersebut (Ardhani et al., 2021).

Ironi dalam Teks Ulasan

Ironi dalam analisis sentimen sering kali terjadi ketika kata-kata yang digunakan berlawanan dengan makna yang dimaksud. Dalam ulasan produk, misalnya, konsumen mungkin menggunakan kata-kata positif seperti “luar biasa” atau “terbaik”, meskipun sebenarnya merujuk pada produk atau layanan yang buruk. Contoh kalimat seperti "Produk ini luar biasa, meskipun sering rusak" mengandung ironi, karena kata “luar biasa” seharusnya menunjukkan sentimen positif, namun konteks kalimat justru mengarah pada sentimen negatif. Identifikasi ironi dalam teks ulasan menjadi tantangan besar, terutama bagi Model sentimen tradisional yang kesulitan dalam memahami hubungan kontras antar kata dalam kalimat. Sebagai contoh, model berbasis Support Vector Machine (SVM) seringkali gagal dalam menangkap ironi karena model ini mengklasifikasikan kata “luar biasa” sebagai sentimen positif tanpa memperhitungkan konteks kalimat secara keseluruhan. Untuk mengatasi permasalahan ini, teknik deep learning seperti Bidirectional Long Short-Term Memory (BiLSTM) mulai diterapkan, yang mampu menangani ketergantungan jangka panjang dalam kalimat dan mengenali ironi dengan lebih baik. BiLSTM memproses informasi dalam dua arah—kiri ke kanan dan sebaliknya—sehingga dapat menangkap kontras dan ketidakcocokan antar kata dalam kalimat. Meski teknik ini lebih efektif dalam mengidentifikasi ironi, tantangan utama adalah kebutuhan akan data pelatihan yang besar dan beragam yang mencakup berbagai contoh ironi .

Sindiran dalam Teks Ulasan

Sindiran merupakan bentuk ironi yang lebih halus dan sering digunakan untuk menyampaikan kritik atau ketidakpuasan secara tidak langsung. Dalam konteks ulasan produk, konsumen yang kecewa dengan produk atau layanan cenderung menggunakan sindiran sebagai cara untuk menyampaikan ketidakpuasan mereka tanpa mengungkapkannya secara eksplisit. Kalimat seperti "Produk ini sangat keren... jika Anda suka

barang rusak" atau "Saya sangat suka desainnya, meskipun fungsinya tidak sesuai dengan harapan" sering mengandung sindiran, di mana kata-kata yang seharusnya positif digunakan untuk menyampaikan kritik yang negatif. Sindiran dalam teks ulasan sangat sulit dikenali, terutama oleh Model sentimen yang hanya fokus pada kata-kata individu tanpa mempertimbangkan hubungan antar kata dalam kalimat. Penelitian menunjukkan bahwa sindiran sering memanfaatkan kata-kata yang tampaknya positif, tetapi dikombinasikan dengan konteks yang mengubah maknanya secara keseluruhan. Misalnya, kata "keren" atau "desainnya sangat bagus" dapat dianggap sebagai sentimen positif, padahal dalam konteks keseluruhan kalimat, sentimen yang dimaksud sebenarnya adalah negatif. Untuk mengatasi masalah ini, dibutuhkan model yang dapat memahami hubungan semantik yang lebih kompleks antara kata dan konteks. BERT (Bidirectional Encoder Representations from Transformers) telah digunakan dalam penelitian ini untuk menangani sindiran. BERT menggunakan mekanisme perhatian (attention mechanism) untuk memahami konteks kata dalam kalimat secara lebih mendalam, menjadikannya lebih efisien dalam menangkap sindiran dibandingkan dengan model yang lebih sederhana, seperti SVM. Namun, BERT juga menghadapi tantangan yang sama, yaitu kebutuhan akan dataset pelatihan yang besar dan beragam untuk menangkap sindiran dalam berbagai konteks.

Pendekatan untuk Menangani Ambiguitas, Ironi, dan Sindiran

Mengintegrasikan pemahaman tentang ambiguitas bahasa, ironi, dan sindiran dalam Model sentimen adalah langkah penting untuk meningkatkan akurasi klasifikasi sentimen. Penelitian yang telah dilakukan ini menyarankan penggunaan model hybrid, yang menggabungkan berbagai teknik linguistik untuk menangani tantangan ini dengan lebih baik. Misalnya, menggabungkan teknik berbasis SVM dengan Word2Vec untuk menangkap hubungan semantik, serta menggunakan BERT untuk menangani sindiran dan ironi, memberikan hasil yang lebih efektif dalam memahami konteks yang kompleks.

Selain itu, penggunaan Optuna untuk optimasi hyperparameter dalam model hybrid dapat lebih meningkatkan akurasi analisis sentimen. Optuna memungkinkan pencarian hyperparameter yang lebih efisien dengan mengevaluasi kombinasi parameter yang lebih berfokus pada hasil eksperimen sebelumnya, sehingga menghasilkan model yang lebih baik dalam menangani nuansa semantik yang terkandung dalam teks.

3.2. Pengaruh Variasi Bahasa dalam Sentimen

Bahasa baku dan bahasa tidak baku dalam ulasan produk.

a. Bahasa Baku dalam Ulasan Produk

Bahasa baku merujuk pada bentuk bahasa yang mengikuti aturan atau kaidah yang ditetapkan oleh lembaga bahasa resmi. Dalam analisis sentimen, penggunaan bahasa baku dalam ulasan produk memberikan keuntungan signifikan, karena strukturnya yang konsisten memudahkan pemahaman oleh sistem pembelajaran mesin. Bahasa baku lebih mudah diolah dengan teknik ekstraksi fitur seperti Term Frequency-Inverse Document Frequency (TF-IDF) dan Word2Vec. TF-IDF mengukur pentingnya kata dalam dokumen dan bekerja lebih efektif pada ulasan berbahasa baku, karena model pembelajaran mesin dapat lebih mudah mendeteksi frekuensi kata yang relevan. Word2Vec, yang membangun representasi kata dalam bentuk vektor berdimensi tinggi, lebih efektif dalam menangkap hubungan semantik antar kata yang mengikuti aturan baku. Sebagai contoh, dalam ulasan "Produk ini sangat berkualitas dan mudah digunakan," kata "berkualitas" dan "mudah digunakan" merupakan kata positif dalam bahasa baku dan dapat diklasifikasikan sebagai sentimen positif. Penelitian menunjukkan bahwa model berbasis Support Vector Machine (SVM) yang dilatih dengan ulasan berbahasa baku menghasilkan akurasi lebih tinggi, karena model lebih mudah mengidentifikasi pola dalam teks yang terstruktur (Pratama & Wibowo, 2021). Sebaliknya, ulasan yang menggunakan bahasa tidak baku, seperti "Produk ini keren banget, ga nyesel beli!" menghadirkan tantangan,

karena ketidaksesuaian dengan kaidah bahasa baku menurunkan akurasi klasifikasi model

b. Implikasi Penggunaan Bahasa Baku dan Tidak Baku pada Model Pembelajaran Mesin

Variasi bahasa dalam analisis sentimen, khususnya dalam ulasan produk e-commerce, memiliki dampak signifikan terhadap akurasi dan efektivitas model yang digunakan. Penggunaan slang, dialek, dan ekspresi lokal sering kali muncul dalam komunikasi sehari-hari, terutama pada platform e-commerce dan media sosial. Variasi bahasa ini mempengaruhi cara model dalam menginterpretasikan sentimen dalam teks ulasan produk, yang bisa menurunkan kinerja model jika tidak ditangani dengan baik. Di Indonesia, yang memiliki kekayaan bahasa daerah dan variasi dialek, tantangan ini menjadi semakin kompleks. Penelitian dalam bidang analisis sentimen perlu mengatasi dinamika keberagaman bahasa tersebut untuk meningkatkan kemampuan model dalam mengidentifikasi sentimen yang terkandung dalam ulasan. Hal ini sangat penting agar model dapat lebih akurat dalam menganalisis ulasan yang menggunakan bahasa sehari-hari, termasuk slang dan ekspresi lokal. Dengan memahami perbedaan-perbedaan ini, model dapat lebih efektif dalam menangkap konteks dan makna dari ulasan produk yang ditulis dalam berbagai bentuk bahasa, baik baku maupun tidak baku. Oleh karena itu, penelitian yang mendalam mengenai pengaruh variasi bahasa terhadap analisis sentimen sangat diperlukan, terutama di negara dengan keragaman bahasa seperti Indonesia (Pratama & Wibowo, 2021).

Pengaruh slang, dialek, dan ekspresi lokal dalam interpretasi sentimen.

Variasi bahasa dalam analisis sentimen, khususnya yang muncul dalam ulasan produk e-commerce, memainkan peran penting dalam menentukan akurasi dan efektivitas dari Model yang digunakan.

Penggunaan slang, dialek, dan ekspresi lokal dapat memengaruhi cara model dalam menginterpretasikan sentimen yang terkandung dalam teks ulasan produk. Oleh karena itu, sangat penting bagi penelitian dalam bidang ini untuk mengatasi dan memahami dinamika keberagaman bahasa yang muncul dalam masyarakat, terutama di negara dengan banyak variasi bahasa seperti Indonesia.

Pengaruh Slang dalam Interpretasi Sentimen

Slang merupakan istilah atau ungkapan tidak baku yang sering digunakan dalam percakapan sehari-hari dan umumnya dipahami oleh kelompok tertentu atau dalam konteks sosial tertentu. Dalam bahasa Indonesia, contoh slang seperti "mantul" yang berarti "mantap betul" atau "baper" yang merujuk pada seseorang yang terlalu emosional, dapat memperumit analisis sentimen, terutama jika model pembelajaran mesin tidak mengenali slang tersebut. Misalnya, kalimat "Barang ini mantul banget!" dalam ulasan e-commerce menunjukkan sentimen sangat positif. Namun, jika model tidak dilatih untuk mengenali slang ini, analisis sentimen yang dihasilkan bisa tidak akurat dan berisiko menyebabkan kesalahan interpretasi dalam pengambilan keputusan berbasis data (Ardhani, Chamidah, & Saifudin, 2021). Penelitian ini menekankan pentingnya preprocessing data untuk menangani slang, misalnya dengan mengubah istilah slang menjadi bentuk baku atau menghapusnya dari dataset. Hal ini penting agar model pembelajaran mesin dapat lebih akurat dalam mengidentifikasi dan mengklasifikasikan sentimen. Dalam eksperimen yang dijelaskan, penggunaan teknik tokenisasi dan normalisasi pada dataset yang mengandung slang menunjukkan hasil yang signifikan. Penggunaan teknik seperti TF-IDF dan Word2Vec juga meningkatkan akurasi model Support Vector Machine (SVM) setelah dilakukan penyesuaian terhadap slang, yang terlihat dari peningkatan akurasi dalam klasifikasi sentimen positif atau negatif (Ardhani, Chamidah, & Saifudin, 2021).

Tabel 1. Daftar Slang dan Penanganannya dalam Dataset Ulasan E-Commerce

Slang	Padanan Baku	Penanganan
Mantul	Mantap Betul	Diperbaiki menjadi "mantap"
Baper	Terlalu Sensitif	Diperbaiki menjadi "terlalu emosional"
Ciyus	Serius	Diperbaiki menjadi "serius"

Pengaruh Dialek dalam Interpretasi Sentimen

Dialek merupakan variasi bahasa yang digunakan oleh kelompok sosial atau geografis tertentu, yang dapat memengaruhi pemahaman kalimat dan hasil analisis sentimen. Sebagai contoh, kata "lumayan" di Jakarta dapat diartikan positif, sementara di daerah lain bisa menunjukkan arti yang biasa saja. Perbedaan semantik ini menambah tantangan dalam analisis sentimen, terutama ketika model tidak dirancang untuk menangani variasi dialek. Oleh karena itu, pengolahan dialek dalam teks menjadi aspek penting yang harus dioptimalkan agar model pembelajaran mesin, seperti SVM, dapat mengklasifikasikan sentimen dengan benar. Teknik Word2Vec terbukti lebih efektif daripada TF-IDF dalam mengenali dan mengatasi masalah akibat perbedaan dialek. Word2Vec mengubah kata-kata menjadi vektor berdimensi tinggi, memungkinkan model untuk memahami hubungan semantik antar kata dalam konteks yang lebih luas, termasuk variasi dialek. Penggunaan Word2Vec dapat membantu model mengenali makna kata yang mempengaruhi sentimen meskipun terdapat perbedaan dialek. Selain itu, optimasi menggunakan Optuna juga berkontribusi meningkatkan akurasi model SVM dalam menangani data dengan variasi dialek, mencapai akurasi hingga 87% dibandingkan dengan model yang tidak disesuaikan untuk dialek.

Pengaruh Ekspresi Lokal dalam Interpretasi Sentimen

Ekspresi lokal sering kali mengandung makna yang lebih dalam dan tidak selalu dapat dipahami dengan cara yang sama seperti bahasa baku. Ungkapan seperti "cuci mata" yang umum digunakan di Jakarta, misalnya, dapat berarti "berjalan-jalan", tetapi dalam konteks lain, bisa memiliki arti yang lebih negatif atau berbeda. Fenomena semacam ini menciptakan tantangan bagi Model sentimen dalam memahami makna yang terkandung dalam ekspresi lokal. Penelitian menunjukkan bahwa Word2Vec mampu menangkap hubungan semantik antar kata dalam ekspresi lokal dengan lebih baik dibandingkan teknik lain seperti TF-IDF. Word2Vec mengubah kata-kata menjadi vektor berdimensi tinggi yang memungkinkan model untuk memahami konteks yang lebih luas dan lebih kompleks, seperti dalam hal ekspresi lokal. Sebagai contoh, dalam eksperimen yang dilakukan, kalimat "cuci mata" dapat dipahami dengan tepat oleh model yang menggunakan Word2Vec, karena model ini dapat mengenali ekspresi semacam ini dalam berbagai konteks. Sebaliknya, TF-IDF, yang hanya bergantung pada frekuensi kata, kesulitan dalam menangani ekspresi lokal yang membutuhkan pemahaman semantik lebih dalam. Berdasarkan hasil eksperimen yang disajikan, penggunaan Word2Vec menunjukkan peningkatan akurasi dalam mengenali sentimen yang terkandung dalam ekspresi lokal, berkontribusi pada akurasi model yang lebih tinggi.

Tabel 2. Perbandingan Akurasi Model TF-IDF dan Word2Vec pada Ekspresi Lokal

Model	Akurasi	Precision	Recall	F1-Score
TF-IDF	83.5%	84.5%	83.2%	83.8%
Word2Vec	87%	86%	85%	85.5%

3.3. Teknologi NLP dan Perannya dalam Analisis Sentimen

Pengolahan bahasa alami (NLP) dalam mengatasi keragaman bahasa dalam teks.

Pengolahan Bahasa Alami (Natural Language Processing, NLP) memainkan peran penting dalam analisis sentimen, terutama dalam memproses teks tidak terstruktur, seperti ulasan produk di platform e-commerce. Teks ulasan yang menggunakan berbagai bentuk bahasa, slang, dan kalimat ambigu sering menambah kesulitan dalam menentukan sentimen yang terkandung di dalamnya. NLP mengatasi tantangan ini dengan beberapa teknik, seperti tokenisasi, penghapusan stopwords, dan stemming. Tokenisasi memecah teks menjadi unit terkecil, memungkinkan model untuk fokus pada kata-kata yang relevan (Dong et al., 2020). Penghapusan stopwords mengurangi kata-kata yang tidak memberikan kontribusi signifikan terhadap analisis, sementara stemming menyederhanakan kata-kata ke bentuk dasarnya, sehingga mengurangi variasi yang tidak perlu (Alshari et al., 2020). Selain itu, teknik berbasis pembelajaran mesin seperti Word2Vec dan TF-IDF juga digunakan untuk meningkatkan akurasi klasifikasi sentimen. Word2Vec mengubah kata menjadi vektor semantik yang menangkap hubungan antar kata, sementara TF-IDF mengukur pentingnya kata dalam konteks dokumen (Su, 2022). Dalam penelitian ini, penggunaan Optuna untuk optimasi hyperparameter pada model SVM menunjukkan peningkatan akurasi dari 79,5% menjadi 87%, memperlihatkan efektivitas teknik tersebut dalam mengatasi keragaman bahasa (Nugraha, 2022).

Tantangan dan solusi dalam analisis sentimen dengan NLP.

Ambiguitas dalam bahasa menjadi tantangan utama dalam analisis sentimen, khususnya dalam ulasan produk yang sering kali mengandung makna yang bertentangan atau tidak langsung. Contohnya, kalimat seperti "produk ini bagus, meskipun agak mahal" menyampaikan sentimen positif terkait kualitas produk, namun ada ketidakpuasan terkait harga. Ketidakjelasan semacam ini meningkatkan kompleksitas analisis karena konsumen tidak selalu mengungkapkan pendapat secara eksplisit. Oleh karena itu, NLP harus mampu menangkap nuansa dan konteks

dalam teks untuk memisahkan sentimen yang tumpang tindih secara tepat (RevMaster.pdf). Sebagai solusi, penerapan model Support Vector Machine (SVM) yang dioptimalkan dengan metode Optuna terbukti efektif dalam mengatasi masalah ini. Dalam penelitian yang dijelaskan di RevMaster.pdf, SVM dengan teknik ekstraksi fitur seperti Word2Vec dapat meningkatkan akurasi analisis sentimen hingga 87%, lebih tinggi dibandingkan dengan penggunaan TF-IDF yang hanya mencapai 83,5%. Word2Vec dapat memahami konteks lebih dalam melalui representasi vektor berdimensi tinggi yang mencakup hubungan semantik antar kata, membantu mengatasi ambiguitas dalam kalimat.

Penggunaan bahasa tidak baku dan variasi dialek dalam ulasan produk juga menambah tantangan analisis sentimen. Misalnya, kata-kata slang atau istilah daerah dalam bahasa Indonesia sering digunakan, yang menyulitkan model berbasis TF-IDF dalam memahami maknanya. Oleh karena itu, diperlukan dataset yang lebih beragam yang mencakup berbagai kategori produk dan variasi bahasa. Penggunaan representasi kata yang lebih kompleks seperti Word2Vec dan GloVe dapat lebih efektif dalam menangkap nuansa makna, memungkinkan model untuk menangani berbagai variasi bahasa dan meningkatkan akurasi dalam klasifikasi sentimen.

Selain itu, teknik seperti TF-IDF hanya mengandalkan frekuensi kata dan tidak dapat menangkap hubungan semantik antar kata dalam kalimat. Misalnya, kata "bank" dalam kalimat yang berbeda bisa memiliki makna yang sangat berbeda, namun TF-IDF akan memperlakukan kata tersebut secara terpisah tanpa mempertimbangkan konteks. Word2Vec, yang mengonversi kata menjadi vektor berdimensi tinggi, mampu mengatasi kekurangan ini dengan menangkap makna semantik yang lebih dalam berdasarkan konteks penggunaannya, yang pada akhirnya meningkatkan akurasi model.

Ironi dan sindiran juga menjadi masalah besar dalam analisis sentimen karena kata-kata yang digunakan sering kali bertentangan dengan makna sebenarnya. Misalnya, kalimat "produk ini luar biasa, meskipun sedikit mahal" tidak mencerminkan sentimen negatif meskipun menggunakan kata "mahal". Salah satu solusi untuk ini adalah penggunaan BiLSTM (Bidirectional Long Short-Term Memory), yang

memproses teks dari dua arah untuk menangkap ketergantungan jangka panjang antar kata, sehingga lebih efektif dalam memahami konteks dan menangani ironi atau sindiran.

BAB 4

Support Vector Machine (SVM) untuk Klasifikasi Sentimen

4.1. Teori Dasar SVM

Prinsip dasar SVM hyperplane dan margin.

Hyperplane adalah sebuah subruang dalam ruang berdimensi tinggi yang digunakan oleh SVM untuk memisahkan data ke dalam dua kelas. Dalam konteks dua dimensi, hyperplane dapat dianggap sebagai garis yang membagi bidang menjadi dua bagian. Di dalam ruang berdimensi n , hyperplane dinyatakan dengan persamaan:

$$w \cdot x + b = 0$$

Dimana w adalah vektor bobot yang ortogonal terhadap hyperplane, x adalah vektor fitur dari data, dan b adalah bias. Vektor bobot w menentukan arah dan kemiringan hyperplane, sedangkan bias b menentukan posisi hyperplane dalam ruang. Dalam konteks analisis sentimen, hyperplane berfungsi untuk memisahkan ulasan produk yang memiliki sentimen positif dari yang negatif, sehingga model SVM dapat memberikan prediksi yang akurat mengenai sentimen yang terkandung dalam ulasan tersebut (Hoiriyah et al., 2023; Rezki et al., 2023).

Margin pada SVM

Margin adalah jarak antara hyperplane dan titik data terdekat dari masing-masing kelas. SVM bertujuan untuk memaksimalkan margin ini, sehingga menciptakan pemisahan yang lebih jelas antara kelas-kelas. Margin didefinisikan sebagai:

$$\text{Margin} = \frac{2}{\|w\|}$$

Dengan memaksimalkan margin, SVM tidak hanya berfokus pada pemisahan data, tetapi juga berusaha untuk meningkatkan generalisasi model pada data yang tidak terlihat. Support vectors adalah titik data yang terletak paling dekat dengan hyperplane dan berperan penting dalam menentukan posisi dan orientasi hyperplane. Hanya titik-titik ini yang mempengaruhi keputusan klasifikasi; titik data lainnya tidak mempengaruhi posisi hyperplane. Dalam konteks analisis sentimen, margin yang lebih besar antara kelas positif dan negatif menunjukkan bahwa model memiliki kepercayaan yang lebih tinggi dalam klasifikasi sentimen (Hoiriyah et al., 2023).

Kernel Trick

Salah satu keunggulan SVM adalah kemampuannya untuk menangani data yang tidak dapat dipisahkan secara linier. SVM menggunakan teknik yang dikenal sebagai kernel trick, yang memungkinkan pemetaan data ke dimensi yang lebih tinggi di mana data dapat dipisahkan secara linier. Beberapa jenis kernel yang umum digunakan dalam SVM antara lain:

1. Linear Kernel

Digunakan ketika data dapat dipisahkan secara linier.

2. **Polynomial Kernel**

Mampu menangani hubungan non-linier antar data.

3. **Radial Basis Function (RBF) Kernel**

Sangat efektif dalam menangani data yang memiliki pola yang sangat tidak linier.

Pemilihan kernel yang tepat sangat penting karena kesalahan dalam pemilihan dapat mengurangi performa model SVM. Oleh karena itu, pemilihan kernel harus disesuaikan dengan karakteristik data yang dihadapi (Hoiriyah et al., 2023; Rezki et al., 2023).

Implementasi SVM dalam Analisis Sentimen

Dalam analisis sentimen, SVM digunakan untuk mengklasifikasikan ulasan produk menjadi dua kategori: positif dan negatif. Dengan menggunakan teknik ekstraksi fitur seperti TF-IDF dan Word2Vec, SVM dapat memanfaatkan informasi yang lebih kaya dari data teks. Penelitian menunjukkan bahwa model SVM yang dioptimasi dengan teknik hyperparameter, seperti GridSearchCV dan RandomizedSearchCV, dapat meningkatkan akurasi klasifikasi sentimen secara signifikan (Hoiriyah et al., 2023; Rezki et al., 2023).

4.2. Penerapan SVM dalam Klasifikasi Sentimen

Menggunakan SVM untuk mengklasifikasikan sentimen positif dan negatif.

Penerapan SVM dalam klasifikasi sentimen positif dan negatif sangat penting untuk memahami persepsi konsumen terhadap produk yang ditawarkan di platform e-commerce. Ulasan produk yang ditulis oleh konsumen sering kali mengandung informasi berharga mengenai

kepuasan atau ketidakpuasan mereka, sehingga analisis sentimen yang akurat dapat membantu perusahaan dalam meningkatkan kualitas produk dan layanan mereka (Ardhani et al., 2021; Rezki et al., 2023).

SVM bekerja dengan prinsip dasar mencari hyperplane optimal yang memisahkan dua kelas, yaitu sentimen positif dan negatif. Dalam konteks analisis sentimen, SVM dapat digunakan untuk mengklasifikasikan ulasan produk menjadi dua kategori berdasarkan sentimen yang terkandung dalam teks. Proses klasifikasi ini dimulai dengan pengumpulan data ulasan produk yang telah dilabeli. Dalam penelitian ini, dataset yang digunakan terdiri dari 2.902 ulasan produk berbahasa Indonesia, yang mencakup berbagai kategori produk dari platform e-commerce terkemuka (Hoiriyah et al., 2023).

Keunggulan SVM dalam menangani data berdimensi tinggi.

Salah satu keunggulan utama SVM adalah kemampuannya untuk menangani data berdimensi tinggi. Dalam konteks analisis sentimen, teks sering kali diwakili dalam bentuk vektor dengan ribuan dimensi, terutama ketika menggunakan teknik representasi seperti TF-IDF dan Word2Vec. SVM efektif dalam mengklasifikasikan data ini karena ia tidak terpengaruh oleh jumlah dimensi yang tinggi, dan dapat menemukan pola yang relevan dalam data (Alzami et al., 2020; Jadia, 2023).

a. Pemisahan Non-Linier

Salah satu tantangan dalam analisis sentimen adalah bahwa data tidak selalu dapat dipisahkan secara linier. Dalam banyak kasus, hubungan antara fitur tidak dapat digambarkan dengan garis lurus. SVM menggunakan teknik kernel untuk menangani masalah ini. Kernel memungkinkan SVM untuk memetakan data ke ruang dimensi yang lebih tinggi, di mana data dapat dipisahkan secara linier. Dengan menggunakan kernel yang tepat, seperti Radial Basis Function (RBF) atau polynomial,

SVM dapat menangkap pola yang lebih kompleks dalam data (Pambudi & Suprpto, 2021).

b. Robustness Terhadap Noise

SVM juga dikenal memiliki ketahanan yang baik terhadap noise dalam data. Dalam analisis sentimen, ulasan produk sering kali mengandung kata-kata yang ambigu atau tidak relevan. SVM berfokus pada support vectors, yang merupakan titik data paling informatif yang menentukan hyperplane. Dengan demikian, SVM tidak terpengaruh oleh titik data yang tidak informatif atau outliers, sehingga meningkatkan akurasi klasifikasi (Jadia, 2023; Rezki et al., 2023).

c. Kemampuan Generalisasi

Kemampuan generalisasi SVM juga menjadi keunggulan dalam analisis sentimen. Dengan memaksimalkan margin antara dua kelas, SVM dapat menghasilkan model yang lebih stabil dan dapat diandalkan ketika diterapkan pada data baru yang tidak terlihat sebelumnya. Hal ini sangat penting dalam konteks e-commerce, di mana ulasan produk dapat bervariasi secara signifikan. Penelitian menunjukkan bahwa SVM sering kali menghasilkan akurasi yang lebih baik dibandingkan algoritma lain dalam konteks data berdimensi tinggi (Ardhani et al., 2021; Rezki et al., 2023).

4.3. Implementasi SVM dalam Model Hybrid

Implementasi SVM dalam model hybrid mengikuti metodologi **integrasi hierarkis** yang dirancang untuk mengkombinasikan kelebihan ekstraksi fitur deep learning dan stabilitas klasifikasi mesin vektor.

Fase Ekstraksi Fitur Multilevel

a) **CNN Layer** (Dimensi Mikro)

Mengekstrak pola lokal (n-gram) menggunakan filter konvolusi paralel dengan ukuran kernel berbeda (3, 5, 7). Setiap kernel memindai teks untuk mendeteksi frasa penanda sentimen (*misal: kernel size 3 menangkap "puas banget"*). Output: *feature maps* spasial (Chen, Sun, & Yan, 2023).

b) **BiLSTM Layer** (Dimensi Makro)

Memproses sekuens maju-mundur untuk menangkap ketergantungan kontekstual jangka panjang. Contoh: mengidentifikasi pengaruh kata "tetapi" dalam "*kualitas bagus TETAPI harga mahal*". Lapisan ini menggunakan *gate mechanism* untuk menyimpan informasi relevan (Nguyen, 2021).

2. Fase Fusi Fitur

a) **Concatenation-based Fusion**

Menggabungkan output CNN (*spatial features*) dan BiLSTM (*temporal features*) menjadi vektor fitur terpadu. Proses ini mempertahankan informasi struktural dari kedua lapisan.

b) **Dimensionality Reduction** (Opsional)

PCA atau *autoencoder* diterapkan jika dimensi fitur >1.000 untuk menghindari *curse of dimensionality* (Mirdan, Buyruköğlu, & Baker, 2025).

3. Fase Klasifikasi SVM dengan Optimasi Presisi

a) **Kernel Selection**

Kernel linear (kernel='linear') dipilih untuk efisiensi komputasi dan interpretabilitas pada data high-dimension.

b) **Hyperparameter Tuning**

Parameter kritis C (regularisasi) dan gamma (pengaruh titik data) dioptimalkan via **Optuna**

c) **Class Weighting:**

Memberikan bobot lebih tinggi pada kelas minoritas (`class_weight='balanced'`) untuk menangani ketidakseimbangan data.

BAB 5

Teknik Ekstraksi Fitur dalam Analisis Sentimen

5.1. TF-IDF Representasi Kata Berdasarkan Frekuensi

Konsep dasar TF-IDF dan penerapannya dalam analisis sentimen.

TF-IDF (Term Frequency-Inverse Document Frequency) adalah teknik representasi teks yang banyak digunakan dalam pengolahan bahasa alami, termasuk dalam analisis sentimen (Alzami et al., 2020). TF-IDF menggabungkan dua komponen utama: Term Frequency (TF), yang mengukur frekuensi kata dalam dokumen, dan Inverse Document Frequency (IDF), yang mengukur kelangkaan kata dalam koleksi dokumen. Penghitungan TF-IDF dilakukan dengan mengalikan nilai TF dan IDF, sehingga kata yang sering muncul dalam suatu dokumen tetapi jarang muncul di dokumen lain akan memiliki bobot tinggi (RevMaster.pdf, hal. 21-22).

Dalam analisis sentimen pada ulasan e-commerce, TF-IDF terbukti efektif dalam mengidentifikasi kata-kata kunci yang menandakan sentimen positif atau negatif (Jadia, 2023). Sebagai contoh, kata-kata seperti "bagus" dan "puas" cenderung memiliki bobot tinggi dalam ulasan positif, sedangkan kata seperti "jelek" dan "rugi" mendominasi ulasan negatif (Ardhani et al., 2021). Penelitian yang dijelaskan dalam RevMaster.pdf (hal. 21-22) menggunakan TF-IDF dengan preprocessing ketat, termasuk tokenisasi, penghapusan stopwords, dan stemming menggunakan Sastrawi untuk bahasa Indonesia.

Namun, meskipun efektif, TF-IDF memiliki keterbatasan dalam menangkap hubungan semantik antar kata. Sebagai contoh, frasa seperti "tidak bagus" dapat dianggap sebagai dua kata terpisah dengan makna positif. Untuk mengatasi hal ini, Word2Vec dapat digunakan sebagai alternatif yang lebih memperhatikan konteks. Meski demikian, kelebihan TF-IDF dalam hal efisiensi komputasi dan interpretasi tetap menjadikannya pilihan utama dalam analisis sentimen skala besar (Alzami et al., 2020).

Kelebihan dan keterbatasan TF-IDF dalam menangkap makna semantik.

Dalam pengolahan bahasa alami (Natural Language Processing, NLP), representasi kata memainkan peranan penting dalam memproses teks dan memperoleh pemahaman yang mendalam mengenai konteks dan sentimen. Salah satu teknik yang banyak digunakan dalam representasi kata adalah TF-IDF (Term Frequency-Inverse Document Frequency), yang mengukur pentingnya suatu kata dalam suatu dokumen relatif terhadap seluruh koleksi dokumen. Metode ini mengkombinasikan dua konsep dasar: Term Frequency (TF) yang mengukur frekuensi kemunculan kata dalam sebuah dokumen, dan Inverse Document Frequency (IDF) yang mengukur seberapa langka kata tersebut muncul di seluruh dokumen dalam korpus. Hasil perkalian antara keduanya menghasilkan bobot kata yang menunjukkan seberapa penting kata tersebut dalam konteks dokumen tersebut, serta bagaimana relevansinya dibandingkan dengan koleksi dokumen lainnya.

Definisi dan Perhitungan TF-IDF

Proses perhitungan TF adalah dengan mengukur frekuensi kemunculan suatu kata dalam dokumen tertentu. Semakin sering kata muncul dalam dokumen, semakin tinggi nilai TF-nya. TF dihitung menggunakan rumus berikut:

$$TF = \frac{\text{Jumlah kemunculan kata dalam dokumen}}{\text{Total kata dalam dokumen}}$$

Di sisi lain, IDF mengukur sejauh mana kata tersebut unik atau jarang di seluruh koleksi dokumen. Kata-kata yang sering muncul di banyak dokumen akan memiliki nilai IDF yang rendah, sedangkan kata yang jarang muncul akan memiliki nilai IDF yang tinggi. Rumus perhitungan IDF adalah:

$$IDF = \log \left(\frac{N}{\text{Jumlah dokumen yang mengandung kata tersebut}} \right)$$

di mana N adalah jumlah total dokumen dalam korpus. Dengan demikian, TF-IDF dihitung dengan mengalikan nilai TF dan IDF:

$$TF - IDF = TF \times IDF$$

Hasil penghitungan ini memberikan bobot yang lebih tinggi pada kata-kata yang jarang namun signifikan, sementara kata-kata yang umum dan tidak berkontribusi pada sentimen atau pemahaman konteks akan memiliki bobot rendah.

Kelebihan TF-IDF dalam Menangkap Makna Semantik

Keunggulan utama TF-IDF (Term Frequency-Inverse Document Frequency) terletak pada kemampuannya untuk mengidentifikasi kata-kata yang relevan dan signifikan dalam suatu dokumen, sekaligus mengurangi pengaruh kata-kata yang tidak memberikan informasi berarti. Dalam analisis sentimen, teknik ini memungkinkan model untuk lebih fokus pada kata-kata yang penting dalam menentukan sentimen, seperti kata "positif" atau "negatif", yang memiliki dampak langsung terhadap hasil klasifikasi. TF-IDF bekerja dengan cara mengurangi bobot kata-kata umum seperti "dan", "atau", dan "adalah", sehingga model

dapat memberikan perhatian lebih pada kata-kata yang benar-benar menentukan sentimen dalam teks. Sebagai contoh, dalam analisis sentimen ulasan produk e-commerce, kata seperti "produk", "bagus", dan "harga" cenderung memiliki bobot tinggi karena relevansinya dalam menyampaikan opini positif atau negatif mengenai produk. Hal ini meningkatkan akurasi model dengan memfokuskan perhatian pada kata-kata yang bermakna, daripada kata-kata yang sering muncul tetapi tidak memberikan informasi yang signifikan. Dengan demikian, TF-IDF sangat berguna untuk meningkatkan efektivitas analisis sentimen dalam berbagai aplikasi, terutama dalam konteks analisis ulasan produk online (Alzami et al., 2020; Jadia, 2023).

Keterbatasan TF-IDF dalam Menangkap Makna Semantik

Meskipun TF-IDF (Term Frequency-Inverse Document Frequency) efektif dalam meningkatkan performa Model sentimen, teknik ini memiliki beberapa keterbatasan, terutama dalam hal pemahaman konteks dan makna semantik antar kata dalam kalimat. TF-IDF hanya mengandalkan frekuensi kemunculan kata dalam dokumen dan korpus tanpa mempertimbangkan hubungan antar kata dalam kalimat. Sebagai contoh, dalam kalimat "Saya sangat puas dengan produk ini" dan "Produk ini sangat memuaskan", meskipun kedua kalimat tersebut mengandung sentimen yang serupa, TF-IDF dapat memberikan bobot yang berbeda pada kata "puas" dan "memuaskan", meskipun keduanya memiliki makna yang sama dalam konteks sentimen. Hal ini menunjukkan keterbatasan TF-IDF dalam menangkap makna semantik yang lebih dalam, yang diperlukan dalam analisis sentimen yang kompleks (Alzami et al., 2020).

Selain itu, TF-IDF juga kesulitan menangkap makna kata yang ambigu berdasarkan konteks. Contohnya, kata "bank" dalam kalimat "Saya pergi ke bank untuk menabung" memiliki arti berbeda dengan "bank" dalam kalimat "Saya duduk di tepi bank sungai", namun TF-IDF tidak dapat membedakan kedua makna tersebut. Untuk mengatasi hal ini, teknologi seperti Word2Vec dan BERT dapat digunakan. Word2Vec mengonversi kata menjadi vektor yang mempertimbangkan konteks,

sementara BERT lebih canggih dalam memahami konteks secara bidirectional, membantu pemahaman semantik yang lebih dalam (Jadia, 2023).

5.2. Word2Vec Representasi Semantik Kata

Penggunaan Word2Vec untuk menghasilkan vektor kata berdasarkan konteks.

Word2Vec adalah metode representasi kata yang paling banyak digunakan dalam pengolahan bahasa alami (Natural Language Processing / NLP) yang dikembangkan oleh Mikolov dan timnya pada tahun 2013. Word2Vec menghasilkan vektor kata yang dapat menggambarkan hubungan semantik antar kata dalam sebuah teks. Salah satu keunggulan utama dari Word2Vec dibandingkan dengan teknik representasi kata lainnya, seperti TF-IDF, adalah kemampuannya dalam menangkap konteks kata dalam kalimat secara lebih mendalam. Representasi kata dalam bentuk vektor memungkinkan model untuk mengerti hubungan antar kata berdasarkan konteksnya, yang memberikan pemahaman lebih dalam mengenai makna kata tersebut. Dalam konteks analisis sentimen, kemampuan ini sangat berguna untuk meningkatkan akurasi dalam klasifikasi sentimen, terutama pada ulasan produk e-commerce yang sering kali menggunakan bahasa yang tidak langsung atau ambigu.

Prinsip Dasar Word2Vec

Word2Vec bekerja dengan mengonversi kata-kata dalam sebuah teks menjadi vektor berdimensi tinggi. Model ini dilatih menggunakan dua arsitektur utama: Continuous Bag of Words (CBOW) dan Skip-Gram. Pada arsitektur CBOW, model berusaha memprediksi kata target berdasarkan kata-kata kontekstual di sekitarnya. Misalnya, dalam kalimat "Saya

sedang makan nasi", kata "makan" akan diprediksi berdasarkan konteks kata "Saya" dan "nasi". Sebaliknya, pada arsitektur Skip-Gram, model berusaha memprediksi kata-kata kontekstual berdasarkan kata target. Jika kata targetnya adalah "makan", model akan berusaha memprediksi kata-kata sekitarnya, seperti "Saya" dan "nasi". Keduanya bertujuan menghasilkan representasi vektor kata yang dapat mempelajari hubungan semantik antar kata berdasarkan konteks dalam teks (Mikolov et al., 2013).

Menghasilkan Vektor Kata Berdasarkan Konteks

Keunggulan utama Word2Vec terletak pada kemampuannya untuk mengonversi kata menjadi vektor yang merepresentasikan hubungan semantik antar kata. Dengan menggunakan pendekatan berbasis konteks, Word2Vec dapat menghasilkan representasi yang lebih mendalam dari sebuah kata dibandingkan dengan teknik tradisional seperti TF-IDF yang hanya menghitung frekuensi kata. Misalnya, kata "raja" dan "ratu" yang secara semantik terkait akan memiliki vektor yang berdekatan dalam ruang dimensi tinggi. Hal ini memungkinkan model untuk memahami hubungan antar kata seperti "raja" dan "ratu" dalam konteks yang lebih luas, yang sangat penting dalam analisis sentimen di mana pemahaman tentang hubungan antar kata dapat menentukan sentimen keseluruhan dari sebuah kalimat atau ulasan produk.

Penerapan Word2Vec dalam analisis sentimen pada e-commerce dapat meningkatkan efisiensi model dalam mengklasifikasikan ulasan produk sebagai sentimen positif atau negatif. Hal ini sangat relevan karena ulasan produk sering kali berisi kalimat-kalimat yang menggunakan kata-kata ambigu, atau bahkan ironi, yang memerlukan pemahaman konteks yang lebih dalam. Oleh karena itu, menggunakan model yang dapat menangkap hubungan semantik antar kata, seperti Word2Vec, memberikan keunggulan yang jelas dibandingkan dengan model yang hanya mengandalkan frekuensi kata seperti TF-IDF.

Teknik Skip-Gram dan Continuous Bag of Words (CBOW).

Dalam upaya meningkatkan akurasi analisis sentimen untuk ulasan produk e-commerce berbahasa Indonesia, salah satu teknik yang sangat efektif adalah Word2Vec, yang merupakan metode pembelajaran untuk menghasilkan representasi kata dalam bentuk vektor berdimensi tinggi. Word2Vec, yang dikembangkan oleh Mikolov et al. (2013), mampu menangkap hubungan semantik antar kata berdasarkan konteksnya dalam kalimat atau dokumen. Berbeda dengan metode representasi kata tradisional seperti TF-IDF, Word2Vec tidak hanya mengandalkan frekuensi kata dalam teks, tetapi juga mempertimbangkan bagaimana kata tersebut berhubungan dengan kata lain di sekitarnya. Teknik ini sangat berguna dalam mengatasi tantangan analisis sentimen yang sering kali melibatkan kalimat kompleks dan nuansa yang sulit dijangkau dengan metode klasik. Secara umum, Word2Vec menggunakan dua teknik utama untuk mempelajari representasi kata: Skip-Gram dan Continuous Bag of Words (CBOW). Kedua teknik ini memiliki keunggulan dan kelemahan masing-masing, tergantung pada konteks dan jenis data yang dianalisis.

Skip-Gram

Skip-Gram merupakan salah satu metode dalam Word2Vec yang berfungsi untuk memprediksi kata-kata konteks berdasarkan kata target. Pada teknik ini, model mencoba untuk memprediksi kata-kata yang ada di sekitar kata tertentu dalam kalimat. Sebagai contoh, dalam kalimat "Saya makan nasi di restoran", jika kata "makan" dianggap sebagai kata target, maka Skip-Gram akan mencoba untuk memprediksi kata-kata seperti "saya", "nasi", dan "restoran" sebagai kata-kata konteks yang ada di sekitar kata "makan".

Keunggulan utama dari Skip-Gram adalah kemampuannya untuk menangkap hubungan semantik kata yang lebih jarang atau lebih spesifik, yang mungkin tidak banyak ditemukan dalam corpus besar namun

memiliki arti yang kuat dalam konteks tertentu. Teknik ini terbukti sangat efektif dalam menangkap hubungan antar kata yang jarang atau tidak sering muncul dalam data, seperti yang dibahas dalam penelitian oleh Ardhani et al. (2021) yang menunjukkan bahwa model berbasis Skip-Gram lebih mampu memahami semantik kata yang lebih rumit dan langka. Hal ini sangat relevan dalam analisis sentimen yang melibatkan variasi bahasa yang lebih luas, terutama pada ulasan produk dengan ekspresi atau istilah yang tidak baku.

Continuous Bag of Words (CBOW)

Sementara itu, Continuous Bag of Words (CBOW) berfungsi untuk memprediksi kata target berdasarkan kata-kata kontekstual yang ada di sekitarnya. Teknik ini berbeda dengan Skip-Gram, karena CBOW lebih menekankan pada prediksi kata berdasarkan konteks yang ada, bukan sebaliknya. Sebagai contoh, pada kalimat "Saya makan nasi di restoran", model CBOW akan menggunakan kata-kata seperti "saya", "nasi", dan "restoran" untuk memprediksi kata target "makan".

Meskipun CBOW lebih cepat dalam memproses data karena hanya memprediksi satu kata target dari beberapa kata kontekstual, namun teknik ini cenderung kurang efektif dalam menangkap hubungan semantik antara kata-kata yang jarang atau lebih spesifik. CBOW lebih cocok digunakan dalam korpus besar dengan banyak kata yang sering muncul dan memiliki hubungan kontekstual yang lebih sederhana. Su (2022) mengemukakan bahwa CBOW lebih efisien dalam corpus yang besar dan lebih sering digunakan dalam aplikasi yang memerlukan pemrosesan data dalam jumlah besar dengan kecepatan tinggi, seperti pada analisis sentimen yang melibatkan data ulasan produk dengan kata-kata yang lebih umum.

Perbandingan Antara Skip-Gram dan CBOW

Kedua metode Skip-Gram dan CBOW memiliki kelebihan dan kekurangan masing-masing, tergantung pada kebutuhan analisis. Skip-Gram unggul dalam menangkap hubungan kata yang lebih jarang dan lebih spesifik, yang sering ditemukan dalam analisis sentimen pada ulasan produk yang lebih kompleks. Sementara itu, CBOW lebih cepat dan efisien untuk dataset besar dengan kata-kata yang lebih umum dan sering muncul.

Berdasarkan temuan penelitian ini yang mengaplikasikan Skip-Gram pada analisis sentimen di e-commerce menunjukkan peningkatan akurasi klasifikasi sentimen hingga 87%, dibandingkan dengan penggunaan CBOW yang menunjukkan hasil lebih rendah. Hasil ini menunjukkan bahwa meskipun CBOW lebih efisien dalam hal komputasi, Skip-Gram lebih efektif dalam menangkap nuansa sentimen yang lebih kompleks dalam ulasan produk yang lebih spesifik dan jarang.

5.3. Perbandingan TF-IDF dan Word2Vec

Kelebihan dan kekurangan keduanya dalam analisis sentimen.

a. TF-IDF dalam Analisis Sentimen

TF-IDF adalah teknik ekstraksi fitur yang menilai seberapa penting suatu kata dalam dokumen, dengan mempertimbangkan frekuensi kemunculan kata tersebut dalam dokumen (Term Frequency, TF) serta seberapa jarang kata itu muncul dalam seluruh koleksi dokumen (Inverse Document Frequency, IDF). Tujuan dari metode ini adalah untuk menonjolkan kata-kata yang lebih penting, sekaligus mengurangi pengaruh kata-kata umum yang sering muncul dalam teks seperti kata sambung (Nafis & Awang, 2021). Salah satu keunggulan TF-IDF adalah kemampuannya untuk mengurangi pengaruh kata-kata yang tidak memberikan banyak informasi, seperti "dan" atau "adalah". Hal ini

menjadikan TF-IDF sangat efisien dalam mengelola dataset teks yang lebih kecil dan sederhana, serta dapat mengurangi dimensi fitur dengan cukup efektif.

Namun, kekurangan utama dari TF-IDF adalah bahwa ia tidak mempertimbangkan hubungan kontekstual antar kata. Teknik ini hanya memperhitungkan frekuensi kata dalam dokumen, tanpa memperhatikan apakah kata tersebut terkait secara semantik dengan kata-kata lain dalam kalimat. Hal ini dapat membatasi efektivitas TF-IDF dalam analisis sentimen yang melibatkan hubungan semantik lebih kompleks antara kata-kata dalam sebuah teks (Ardhani et al., 2021). Sebagai contoh, kata-kata yang memiliki makna yang sama atau sangat mirip, seperti "baik" dan "bagus", akan dianggap sebagai kata yang terpisah dalam TF-IDF meskipun keduanya memiliki arti yang sama dalam konteks tertentu. Ini dapat menurunkan akurasi model dalam menangani sentimen yang lebih rumit, seperti yang sering dijumpai dalam ulasan produk e-commerce yang menggunakan bahasa yang tidak langsung atau bernuansa.

b. Word2Vec dalam Analisis Sentimen

Berbeda dengan TF-IDF, Word2Vec adalah teknik yang lebih canggih yang menggunakan pembelajaran mendalam (deep learning) untuk mengonversi kata-kata menjadi vektor berdimensi tinggi. Teknik ini berfungsi dengan cara mempelajari asosiasi antara kata-kata berdasarkan konteks penggunaannya dalam kalimat. Dengan menggunakan dua arsitektur utama—Continuous Bag of Words (CBOW) dan Skip-Gram—Word2Vec dapat menangkap hubungan semantik antar kata dengan cara memprediksi kata target berdasarkan kata-kata kontekstual di sekitarnya (Rezki et al., 2023). CBOW bekerja dengan cara memprediksi kata target menggunakan kata-kata kontekstual yang ada di sekitarnya, sedangkan Skip-Gram melakukan kebalikannya dengan memprediksi kata-kata kontekstual berdasarkan kata target.

Keunggulan utama dari Word2Vec adalah kemampuannya untuk menangkap hubungan semantik yang lebih dalam antar kata. Misalnya, Word2Vec dapat memahami bahwa kata "raja" dan "ratu" memiliki hubungan yang lebih erat dibandingkan dengan kata "raja" dan "meja" dalam konteks tertentu. Hal ini sangat bermanfaat untuk analisis

sentimen dalam e-commerce, di mana ulasan produk sering kali mengandung nuansa dan konotasi yang lebih dalam. Model ini mampu menangani teks yang lebih kompleks dan lebih bernuansa, seperti yang sering ditemukan dalam ulasan produk yang menggunakan bahasa yang tidak langsung atau penuh ironi. Dengan kata lain, Word2Vec dapat memanfaatkan konteks yang lebih luas untuk meningkatkan akurasi analisis sentimen (Gandhi et al., 2023).

Namun, kelemahan utama dari Word2Vec adalah bahwa ia membutuhkan data pelatihan yang sangat besar untuk menghasilkan representasi kata yang efektif. Tanpa cukup data, model ini tidak dapat belajar dengan baik dan dapat menghasilkan representasi kata yang kurang akurat. Selain itu, meskipun Word2Vec lebih baik dalam menangkap hubungan semantik, representasi vektor yang dihasilkannya seringkali sulit untuk diinterpretasikan secara langsung, sehingga menambah kompleksitas dalam analisis hasil dan evaluasi model.

c. Perbandingan TF-IDF dan Word2Vec dalam Analisis Sentimen

Meskipun TF-IDF dan Word2Vec keduanya digunakan untuk tujuan yang sama, yaitu untuk mengekstraksi fitur dari teks, kedua teknik ini memiliki kelebihan dan kelemahan yang berbeda yang membuat mereka lebih cocok untuk digunakan dalam situasi yang berbeda pula. Kelebihan TF-IDF adalah kemampuannya untuk bekerja dengan cepat pada dataset yang lebih kecil dan lebih sederhana. TF-IDF juga sangat efisien dalam hal komputasi dan memori, sehingga cocok digunakan untuk menganalisis ulasan produk yang lebih eksplisit dan langsung, di mana kata-kata dalam teks cenderung tidak terlalu kompleks. Selain itu, TF-IDF cukup sederhana untuk diimplementasikan dan dapat memberikan hasil yang baik dalam situasi di mana hubungan semantik antara kata-kata dalam kalimat tidak terlalu penting.

Namun, Word2Vec lebih unggul dalam menangani teks yang lebih kompleks dan bernuansa. Dengan kemampuannya untuk menangkap makna semantik antar kata berdasarkan konteks, Word2Vec lebih efektif dalam menangani teks yang mengandung ironi, sindiran, atau bahasa tidak langsung yang sering ditemukan dalam ulasan produk di platform

e-commerce. Word2Vec juga lebih baik dalam menangkap hubungan semantik antar kata yang memiliki arti yang mirip, yang menjadikannya lebih fleksibel dalam menangani berbagai jenis teks (Rezki et al., 2023). Meskipun membutuhkan data pelatihan yang lebih besar, hasil yang diberikan oleh Word2Vec dalam analisis sentimen pada teks yang kompleks sering kali lebih akurat daripada TF-IDF.

Implementasi masing-masing teknik dalam analisis ulasan produk.

1. Teknik TF-IDF dalam Analisis Ulasan Produk

2.

TF-IDF adalah metode yang populer dalam analisis teks yang digunakan untuk menentukan seberapa penting suatu kata dalam dokumen. Teknik ini menggabungkan dua komponen utama: Term Frequency (TF), yang mengukur seberapa sering kata muncul dalam dokumen, dan Inverse Document Frequency (IDF), yang mengukur seberapa jarang kata tersebut muncul di seluruh dokumen dalam koleksi. Dengan demikian, TF-IDF memberikan bobot yang lebih tinggi pada kata-kata yang lebih relevan dan spesifik, serta mengurangi pengaruh kata-kata yang sering muncul dalam dokumen lainnya, yang tidak memberikan banyak informasi.

Dalam analisis sentimen ulasan produk e-commerce, TF-IDF digunakan untuk mengidentifikasi kata-kata yang penting dalam setiap ulasan produk, sehingga memungkinkan model untuk lebih fokus pada elemen-elemen kunci dalam teks tersebut. Model TF-IDF menghitung bobot untuk setiap kata dalam dataset ulasan produk. Hasilnya kemudian diproses dalam bentuk array dan diubah menjadi DataFrame untuk mempermudah analisis lebih lanjut. TF-IDF memungkinkan model untuk mengurangi kata-kata umum yang tidak relevan dan memperbesar bobot kata-kata yang lebih unik atau penting dalam konteks ulasan produk. Namun, meskipun TF-IDF efektif untuk menangani teks dengan struktur yang lebih sederhana, teknik ini tidak mempertimbangkan hubungan semantik antar kata dalam teks. Sebagai contoh, meskipun kata "bagus"

dan "hebat" memiliki arti yang serupa dalam konteks ulasan produk, TF-IDF akan memperlakukannya sebagai dua kata yang terpisah dan tidak dapat menangkap hubungan kontekstual di antara keduanya.

2. Teknik Word2Vec dalam Analisis Ulasan Produk

Berbeda dengan TF-IDF, Word2Vec adalah metode representasi kata yang berbasis pada pembelajaran mendalam. Teknik ini menggunakan model jaringan saraf untuk membangun representasi kata dalam bentuk vektor berdimensi tinggi yang mencerminkan hubungan semantik antar kata. Dengan kata lain, Word2Vec tidak hanya memperhatikan kemunculan kata dalam dokumen, tetapi juga bagaimana kata-kata tersebut saling berhubungan dalam konteks kalimat. Word2Vec menggunakan dua arsitektur utama: Continuous Bag of Words (CBOW) dan Skip-Gram. CBOW memprediksi kata target berdasarkan kata-kata yang ada di sekitarnya, sedangkan Skip-Gram memprediksi kata-kata kontekstual berdasarkan kata target.

Word2Vec diterapkan pada dataset ulasan produk yang telah diproses untuk mengonversi kata-kata dalam teks menjadi vektor yang dapat dimengerti oleh model. Model Word2Vec digunakan untuk membangun representasi kata yang lebih kompleks dengan menangkap hubungan semantik antar kata berdasarkan konteks penggunaannya dalam kalimat. Misalnya, jika dalam ulasan disebutkan "produk ini luar biasa dan sangat memuaskan," Word2Vec akan memahami bahwa "luar biasa" dan "memuaskan" memiliki makna yang mirip, meskipun keduanya tidak selalu muncul bersama dalam dokumen yang sama.

Keunggulan utama Word2Vec dibandingkan TF-IDF adalah kemampuannya untuk menangkap hubungan semantik antara kata-kata, yang memberikan pemahaman yang lebih mendalam tentang teks. Teknik ini memungkinkan model untuk memahami makna yang lebih kompleks dari ulasan produk, di mana konteks dan hubungan antar kata sangat penting dalam menentukan sentimen. Namun, Word2Vec juga memiliki kelemahan, yaitu memerlukan data pelatihan yang lebih besar dan sumber daya komputasi yang lebih tinggi dibandingkan TF-IDF.

3. Perbandingan Kinerja TF-IDF dan Word2Vec

Berdasarkan hasil penelitian ini, perbandingan antara TF-IDF dan Word2Vec menunjukkan bahwa Word2Vec secara signifikan mengungguli TF-IDF dalam hal akurasi klasifikasi sentimen. Penggunaan Word2Vec menghasilkan akurasi sekitar 87%, sementara TF-IDF hanya mencapai 83,5%. Selain itu, Word2Vec juga menunjukkan hasil yang lebih baik dalam hal precision, recall, dan F1-score, yang menunjukkan kemampuannya dalam menangkap nuansa semantik yang lebih halus dalam ulasan produk. Tabel berikut merangkum hasil perbandingan kedua teknik ini berdasarkan evaluasi model yang dilakukan dalam penelitian:

Tabel 2. Perbandingan hasil evaluasi TF-IDF dan Word2Vec

Teknik	Precision	Recall	F1-Score	Akurasi
TF-IDF	83.5%	80.7%	81.6%	83.5%
Word2Vec	84.5%	83.2%	83.8%	87.0%

Tabel 2 menyajikan perbandingan antara dua teknik representasi kata dalam analisis sentimen, yaitu TF-IDF dan Word2Vec, dengan menggunakan empat metrik utama: precision, recall, F1-score, dan akurasi. Precision mengukur akurasi model dalam mengklasifikasikan sentimen positif, di mana TF-IDF mencapai 83,5% dan Word2Vec sedikit lebih tinggi di 84,5%. Meskipun perbedaannya kecil, Word2Vec sedikit lebih unggul dalam memprediksi ulasan positif (Alzami et al., 2020). Recall, yang mengukur seberapa banyak sentimen positif dalam data yang berhasil ditangkap, menunjukkan nilai 80,7% untuk TF-IDF dan 83,2% untuk Word2Vec, yang menandakan bahwa Word2Vec lebih efektif dalam menangkap sentimen positif yang tersebar dalam data (Jadia, 2023). F1-score, sebagai rata-rata harmonik antara precision dan recall, menunjukkan nilai 81,6% untuk TF-IDF dan 83,8% untuk Word2Vec, yang mengindikasikan bahwa Word2Vec lebih seimbang dalam menangani kedua metrik ini. Akurasi, yang mengukur proporsi prediksi yang benar, menunjukkan hasil 83,5% untuk TF-IDF dan 87,0% untuk

Word2Vec, dengan Word2Vec menunjukkan kinerja yang lebih baik secara keseluruhan

BAB 6

Preprocessing Data Teks untuk Analisis Sentimen

6.1. Teknik Preprocessing dalam NLP

Tokenisasi, penghapusan stopwords, dan stemming.

a. Tokenisasi

Tokenisasi adalah langkah pertama dalam preprocessing teks yang memecah teks panjang menjadi unit-unit lebih kecil, yang disebut token. Token ini dapat berupa kata, karakter, atau sub-kata, tergantung pada jenis tokenisasi yang diterapkan. Dalam analisis sentimen, tokenisasi dilakukan pada level kata, di mana setiap kata dalam kalimat dipisahkan untuk dianalisis lebih lanjut. Misalnya, kalimat "Produk ini sangat bagus" dipecah menjadi empat token: "Produk", "ini", "sangat", dan "bagus". Proses ini memungkinkan model untuk lebih mudah menilai frekuensi dan hubungan antar kata, yang penting dalam analisis sentimen untuk menentukan polaritas teks (Alzami et al., 2020).

```
[4] import nltk
    from nltk.tokenize import word_tokenize

    # Download all required NLTK data (lebih lengkap)
    nltk.download('all', quiet=True)

    # Contoh kalimat
    text = "Produk ini sangat bagus"

    # Melakukan tokenisasi
    tokens = word_tokenize(text)
    print(tokens)
```

```
→ ['Produk', 'ini', 'sangat', 'bagus']
```

Gambar 1. Contoh Tokenisasi

b. Penghapusan Stopwords

Setelah teks dipecah menjadi token, langkah berikutnya adalah penghapusan stopwords. Stopwords adalah kata-kata yang sering muncul tetapi tidak memberikan informasi signifikan untuk analisis, seperti kata sambung atau preposisi, misalnya "dan", "adalah", "yang". Meskipun berfungsi secara gramatikal, kata-kata ini tidak mempengaruhi pemahaman sentimen atau makna teks secara mendalam. Penghapusan stopwords bertujuan untuk memungkinkan model fokus pada kata-kata yang lebih informatif dan relevan dengan analisis sentimen. Misalnya, dalam kalimat "Produk ini sangat bagus dan memuaskan", kata "dan" dapat dihapus karena tidak menambah informasi. Proses ini dilakukan menggunakan alat seperti nltk (Alzami et al., 2020).

```
from nltk.corpus import stopwords

# Daftar stopwords dalam bahasa Indonesia
stop_words = set(stopwords.words('indonesian'))

# Contoh teks
text = "Produk ini sangat bagus dan memuaskan"

# Tokenisasi
tokens = word_tokenize(text)

# Menghapus stopwords
filtered_words = [word for word in tokens if word.lower() not in stop_words]
print(filtered_words)
```

➡ ['Produk', 'bagus', 'memuaskan']

Gambar 2. Stopwords

c. Stemming

Stemming adalah teknik untuk mengurangi kata-kata ke bentuk dasar atau akar kata, yang bertujuan menyatukan berbagai bentuk kata yang memiliki makna serupa. Dalam bahasa Indonesia, kata-kata seperti "berjalan", "berjalan-jalan", dan "jalan" memiliki akar kata yang sama, yaitu "jalan". Tanpa stemming, model akan menganggap kata-kata ini

sebagai entitas yang berbeda. Proses ini penting dalam analisis sentimen karena memungkinkan model mengkonsolidasikan kata-kata yang memiliki makna yang sama, meningkatkan kemampuan model dalam memproses data teks. Stemming pada bahasa Indonesia dapat dilakukan menggunakan pustaka Sastrawi (Alzami et al., 2020).

```
!pip install Sastrawi

from Sastrawi.Stemmer.StemmerFactory import StemmerFactory

# Membuat objek stemmer
factory = StemmerFactory()
stemmer = factory.create_stemmer()

# Contoh kata yang akan distem
text = "berjalan-jalan di taman"

# Proses stemming
stemmed_text = stemmer.stem(text)
print(stemmed_text)
```

Collecting Sastrawi
 Downloading Sastrawi-1.0.1-py2.py3-none-any.whl.metadata (909 bytes)
 Downloading Sastrawi-1.0.1-py2.py3-none-any.whl (209 kB)
 209.7/209.7 kB 4.0 MB/s eta 0:00:00
Installing collected packages: Sastrawi
Successfully installed Sastrawi-1.0.1
jalan di taman

Gambar 3. Stemming

Penerapan teknik-teknik ini untuk meningkatkan kualitas data ulasan produk.

Pada tahap pertama analisis sentimen menggunakan teknik Natural Language Processing (NLP), preprocessing data memegang peranan penting. Proses ini bertujuan untuk mempersiapkan data teks agar lebih bersih dan terstruktur sebelum diterapkan dalam Model. Dalam konteks e-commerce, data ulasan produk yang tidak terstruktur memerlukan pembersihan dan transformasi agar model dapat memprosesnya dengan efisien dan akurat. Beberapa teknik preprocessing penting yang diidentifikasi dalam RevMaster.pdf dan Data Final.pdf, seperti pembersihan data, tokenisasi, penghapusan stopwords, dan stemming,

dapat meningkatkan kualitas data ulasan produk yang digunakan dalam analisis sentimen

Pembersihan Teks (Data Cleaning)

Pembersihan teks merupakan langkah pertama dalam preprocessing yang bertujuan menghilangkan elemen-elemen yang tidak relevan dalam data, seperti angka, simbol, dan elemen lain yang tidak berkontribusi terhadap analisis sentimen. Dalam RevMaster.pdf, pembersihan teks melibatkan penghapusan elemen-elemen yang dapat mengganggu model analitik, seperti mentions (@username), hashtags (#hashtag), URL, angka, dan emotikon (p. 5). Langkah ini sangat penting karena elemen-elemen tersebut menambah kompleksitas data tanpa memberikan informasi yang signifikan untuk analisis sentimen. Sebagai contoh, dalam analisis sentimen terhadap ulasan produk, URL atau emotikon tidak memberikan informasi yang relevan dalam menentukan sentimen pengguna terhadap produk tersebut. Oleh karena itu, pembersihan teks membantu memfokuskan model pada elemen-elemen yang lebih penting, seperti kata-kata yang mengandung sentimen positif atau negatif. Proses ini meningkatkan kualitas data ulasan produk yang akan dianalisis, mempermudah model dalam mengenali sentimen yang ada dan menghindari gangguan dari informasi yang tidak relevan

```
import re
def datacleaning(text):
    text = re.sub(r'@[A-Za-z0-9]+', '', text) # Menghapus mentions (@username)
    text = re.sub(r'[^0-9a-zA-Z]+', '', text) # Menghapus simbol non-alfanumerik
    text = re.sub(r'#[A-Za-z0-9]+', '', text) # Menghapus hashtag (#contoh)
    text = re.sub(r"http\S+", '', text) # Menghapus URL (http://...)
    text = re.sub(r'[0-9]+', '', text) # Menghapus angka
    text = re.sub('\n', ' ', text) # Mengganti newline jadi spasi
    text = re.sub('\t', ' ', text) # Mengganti tab jadi spasi
    text = text.strip(' ') # Menghapus spasi di awal/akhir
    return text

# Contoh teks kotor
dirty_text = """
@user123 Ini adalah contoh teks!
Terdiri dari #hashtag, http://example.com,
angka 123, dan simbol &%%.
Juga ada enter
dan\t tab.
"""

# Membersihkan teks
clean_text = datacleaning(dirty_text)
print("Sebelum cleaning:")
print(dirty_text)
print("\nSetelah cleaning:")
print(clean_text)
```

Gambar 4. Data Cleaning

Berdasarkan Gambar 4, proses data cleaning dilakukan untuk membersihkan teks dari berbagai elemen yang tidak diinginkan seperti mentions (@username), hashtag (#contoh), URL (http://...), angka, simbol non-alfanumerik, serta karakter khusus seperti newline dan tab. Fungsi datacleaning menggunakan modul re (regular expression) untuk melakukan substitusi atau penghapusan terhadap elemen-elemen tersebut. Contoh teks kotor yang diberikan mencakup berbagai elemen seperti mentions, hashtag, URL, angka, simbol, dan karakter khusus. Setelah melalui proses cleaning, teks menjadi lebih bersih dan hanya terdiri dari huruf alfabet dan spasi. Hasil akhir menunjukkan bahwa semua elemen yang tidak diinginkan telah berhasil dihilangkan, termasuk spasi di awal dan akhir teks. Proses ini sangat penting dalam pra-pemrosesan teks, terutama untuk analisis data atau pemrosesan bahasa alami, karena memastikan konsistensi dan kualitas data yang lebih baik. Dengan demikian, data yang telah dibersihkan siap untuk digunakan dalam tahap analisis atau pemodelan selanjutnya.

Output Program Data Cleaning

Sebelum cleaning:

```
@user123 Ini adalah contoh teks!  
Terdiri dari #hashtag, http://example.com,  
angka 123, dan simbol &*%.  
Juga ada enter  
dan      tab.
```

Setelah cleaning:

Ini adalah contoh teks
Terdiri dari hashtag http example com angka dan simbol
Juga ada enter dan tab

Gambar 5. Output Program Data Cleaning

Berdasarkan Gambar 5, output program data cleaning menunjukkan perbandingan antara teks sebelum dan sesudah proses pembersihan. Sebelum cleaning, teks mengandung berbagai elemen yang tidak diinginkan seperti mention (@user123), hashtag (#hashtag), URL (<http://example.com>), angka (123), simbol (&*%), serta karakter khusus seperti newline dan tab. Setelah melalui proses cleaning, teks menjadi lebih rapi dan hanya terdiri dari kata-kata yang relevan. Hasilnya adalah teks yang telah dibersihkan dari semua elemen non-alfanumerik, termasuk penghapusan angka, simbol, dan karakter khusus. Namun, terlihat bahwa beberapa kata seperti "http example com" masih tersisa

karena proses cleaning hanya menghilangkan simbol tertentu tanpa memperbaiki konteks kalimat. Meskipun demikian, teks hasil cleaning lebih mudah dibaca dan siap untuk diproses lebih lanjut dalam analisis teks atau pemodelan bahasa alami. Proses ini sangat penting dalam pra-pemrosesan data untuk memastikan konsistensi dan kualitas data sebelum digunakan dalam tahap selanjutnya. Dengan demikian, data cleaning membantu meningkatkan akurasi dan keandalan hasil analisis.

6.2. Pengolahan Teks Bahasa Indonesia

Tantangan morfologi dan sintaksis dalam bahasa Indonesia.

a. Tantangan Morfologi dalam Bahasa Indonesia

Morfologi bahasa Indonesia membawa tantangan dalam pengolahan teks karena adanya variasi kata yang dibentuk melalui imbuhan seperti prefiks, infiks, sufiks, dan konfiks. Imbuhan ini dapat mengubah makna kata secara signifikan, seperti "baca" yang dapat menjadi "membaca", "pembaca", atau "terbaca". Hal ini menciptakan tantangan dalam analisis sentimen, memerlukan teknik seperti stemming dan lemmatization untuk mengembalikan kata ke bentuk dasarnya. Meskipun teknik ini membantu, ambiguitas semantik tetap ada. Penggunaan Word2Vec dan TF-IDF membantu dengan mengonversi kata menjadi vektor berdimensi tinggi yang menangkap hubungan semantik antar kata, meskipun dalam bentuk morfologi yang berbeda, yang penting dalam analisis sentimen

b. Tantangan Sintaksis dalam Bahasa Indonesia

Pengolahan teks bahasa Indonesia menghadapi tantangan sintaksis terkait fleksibilitas struktur kalimat. Bahasa Indonesia memiliki aturan sintaksis yang lebih longgar dibandingkan bahasa Inggris, memungkinkan variasi urutan kata tanpa mengubah makna. Sebagai contoh, kalimat "Saya membeli buku" dan "Buku saya beli" memiliki makna yang sama meskipun urutan kata berbeda. Hal ini menyebabkan ambiguitas yang perlu diselesaikan dalam sistem NLP. Untuk mengatasi

masalah ini, teknik parsing sintaksis digunakan untuk mengidentifikasi struktur kalimat dan hubungan antar kata. Model NLP seperti CNN dan BiLSTM juga digunakan untuk menangkap ketergantungan jangka panjang dan memahami konteks kalimat.

Teknik preprocessing yang sesuai dengan karakteristik bahasa Indonesia.

a. Tokenisasi dalam Bahasa Indonesia

Tokenisasi adalah langkah pertama dalam preprocessing teks yang bertujuan untuk membagi teks menjadi unit yang lebih kecil, atau yang dikenal dengan istilah token. Dalam bahasa Indonesia, proses tokenisasi menjadi lebih kompleks karena adanya imbuhan pada kata yang dapat membentuk berbagai varian kata dari satu kata dasar. Misalnya, kata dasar "baca" dapat memiliki bentuk turunan seperti "membaca", "pembaca", dan "terbaca", yang semuanya memiliki makna yang berbeda namun berasal dari kata yang sama. Oleh karena itu, teknik tokenisasi harus dapat memisahkan kata-kata yang berasal dari bentuk turunan yang berbeda agar model dapat menangkap makna yang sesungguhnya.

Pada penelitian ini, tokenisasi dilakukan dengan menggunakan pustaka Python seperti NLTK dan spaCy yang telah dilatih untuk mengenali pola-pola linguistik dalam bahasa Indonesia. Tokenisasi yang tepat sangat membantu dalam menganalisis teks, terutama ketika model perlu menangkap konteks yang terkait dengan variasi kata yang berasal dari imbuhan atau kata turunan.

```
import nltk
from nltk.tokenize import word_tokenize

def Tokenizing(text):
    return word_tokenize(text)

# Contoh penggunaan tokenisasi
text = "Kualitas produk ini sangat bagus dan sesuai dengan ekspektasi."
tokens = Tokenizing(text)
print(tokens)
```

['Kualitas', 'produk', 'ini', 'sangat', 'bagus', 'dan', 'sesuai', 'dengan', 'ekspektasi', '.']

Gambar 6. Proses Tokenisasi

Penghapusan Stopwords

Setelah tokenisasi, langkah berikutnya adalah penghapusan stopwords. Stopwords adalah kata-kata yang sering muncul dalam teks namun tidak memberikan kontribusi berarti terhadap makna utama kalimat. Dalam bahasa Indonesia, kata-kata seperti "dan", "atau", "yang", "adalah", sering ditemukan dalam teks namun tidak memberikan informasi penting untuk analisis lebih lanjut. Oleh karena itu, penghapusan stopwords sangat penting dalam tahap preprocessing untuk mengurangi "noise" yang dapat mengganggu pemahaman model. Penggunaan stopwords dalam bahasa Indonesia sering kali mengacu pada daftar kata umum yang ditentukan oleh sumber-sumber tertentu, seperti NLTK dan Sastrawi. Di dalam penelitian ini, dijelaskan bagaimana daftar stopwords dapat diperluas dan disesuaikan dengan konteks lokal untuk meningkatkan akurasi dalam analisis teks bahasa Indonesia.

```
from nltk.corpus import stopwords
# Daftar stopwords bahasa Indonesia
stop_words = set(stopwords.words('indonesian'))
def Filtering(text):
    clean_words = [word for word in text if word not in stop_words]
    return " ".join(clean_words)
# Contoh penggunaan penghapusan stopwords
text = "Kualitas produk ini sangat bagus dan sesuai dengan ekspektasi."
filtered_text = Filtering(text.split())
print(filtered_text)
```

→ Kualitas produk bagus sesuai ekspektasi.

Gambar 7. Proses Stopwords

Stemming dan Lemmatization

Stemming dan lemmatization adalah dua teknik penting dalam preprocessing untuk mengurangi variasi kata menjadi bentuk dasar atau lemma. Stemming mengubah kata menjadi bentuk dasarnya dengan cara menghilangkan imbuhan yang ada, seperti dalam kata "bermain" menjadi "main". Sementara itu, lemmatization tidak hanya menghilangkan imbuhan tetapi juga mempertimbangkan konteks kata dalam kalimat untuk mengubah kata menjadi bentuk dasarnya yang lebih semantik. Dalam bahasa Indonesia, stemming lebih sering digunakan daripada lemmatization, karena stemmer bahasa Indonesia sudah tersedia dengan mudah.

```
from Sastrawi.Stemmer.StemmerFactory import StemmerFactory

# Membuat instansi stemmer
factory = StemmerFactory()
stemmer = factory.create_stemmer()

# Contoh stemming pada kata-kata
text = "Saya sedang bermain bola di lapangan."
stemmed_text = stemmer.stem(text)
print(stemmed_text)
```

→ saya sedang main bola di lapang

Gambar 8. Stemming dan Lemmatization

6.3. Penggunaan Word Embedding dalam Preprocessing

Mengubah teks menjadi representasi numerik dengan TF-IDF dan Word2Vec.

a. Term Frequency-Inverse Document Frequency (TF-IDF)

TF-IDF (Term Frequency-Inverse Document Frequency) adalah salah satu teknik ekstraksi fitur yang paling banyak digunakan dalam analisis teks. Teknik ini memberikan bobot pada kata-kata dalam sebuah dokumen berdasarkan frekuensi kemunculannya dalam dokumen tersebut dan seberapa sering kata tersebut muncul di seluruh koleksi dokumen. TF terdiri dari dua komponen utama, yaitu Term Frequency (TF) dan Inverse Document Frequency (IDF), yang dihitung dengan mengalikan kedua nilai tersebut untuk menghasilkan nilai pentingnya kata dalam dokumen. TF-IDF efektif untuk meminimalkan pengaruh kata-kata umum seperti "dan" atau "adalah" yang tidak memberikan informasi signifikan. Meskipun demikian, TF-IDF memiliki keterbatasan, yaitu tidak mempertimbangkan hubungan semantik antar kata dalam kalimat. Hal ini sangat penting dalam analisis sentimen, di mana konteks dan makna kata dalam kalimat mempengaruhi interpretasi sentimen. Dalam konteks

ulasan e-commerce, meskipun TF-IDF efektif untuk menilai kata-kata yang sering muncul, seperti nama produk atau fitur, ia mungkin kesulitan dalam menangani kalimat yang mengandung ironi atau ambiguitas, yang memerlukan pemahaman konteks lebih dalam (Alzami et al., 2020).

```
from sklearn.feature_extraction.text import TfidfVectorizer
# Data ulasan
reviews = ["Produk ini bagus", "Saya suka produk ini", "Kualitasnya sangat buruk", "Layanan cepat dan ramah"]
# Membuat representasi TF-IDF
vectorizer = TfidfVectorizer()
X = vectorizer.fit_transform(reviews)
# Menampilkan hasil TF-IDF
print("TF-IDF Matrix:\n", X.toarray())
print("Features (kata-kata):\n", vectorizer.get_feature_names_out())
```

TF-IDF Matrix:

[0.66767854	0.	0.	0.	0.52640543	0.
0.	0.52640543	0.	0.	0.	0.]
[0.	0.	0.	0.	0.43779123	0.
0.	0.43779123	0.	0.	0.55528266	0.55528266]
[0.	0.57735027	0.	0.	0.	0.57735027
0.	0.	0.	0.57735027	0.	0.]
[0.	0.	0.5	0.5	0.	0.]
0.5	0.	0.5	0.	0.	0.]]

Features (kata-kata):

['bagus' 'buruk' 'cepat' 'dan' 'ini' 'kualitasnya' 'layanan' 'produk' 'ramah' 'sangat' 'saya' 'suka']

Gambar 9. Proses TF-IDF

b. Word2Vec

Sementara TF-IDF efisien, ia memiliki keterbatasan dalam menangkap hubungan semantik antar kata. Word2Vec, yang dikembangkan oleh Mikolov et al. (2013), adalah metode representasi kata yang lebih canggih yang dapat menangkap makna semantik dalam konteks kalimat. Menggunakan neural network, Word2Vec mengonversi kata menjadi vektor berdimensi tinggi yang mencerminkan hubungan semantik antar kata. Model utama Word2Vec adalah Continuous Bag of Words (CBOW) dan Skip-gram. Keunggulan Word2Vec dibandingkan TF-IDF adalah kemampuannya memahami hubungan semantik antar kata, seperti "raja" dan "ratu", meskipun memiliki bentuk yang berbeda (Mikolov et al., 2013).

```
[1] pip install gensim

Requirement already satisfied: gensim in /usr/local/lib/python3.11/dist-packages (4.3.3)
Requirement already satisfied: numpy<2.0,>=1.18.5 in /usr/local/lib/python3.11/dist-packages (from gensim) (1.26.4)
Requirement already satisfied: scipy<1.14.0,>=1.7.0 in /usr/local/lib/python3.11/dist-packages (from gensim) (1.13.1)
Requirement already satisfied: smart-open>=1.8.1 in /usr/local/lib/python3.11/dist-packages (from gensim) (7.3.0.post1)
Requirement already satisfied: wrapt in /usr/local/lib/python3.11/dist-packages (from smart-open>=1.8.1->gensim) (1.17.2)

from gensim.models import Word2Vec
from nltk.tokenize import word_tokenize
# Data ulasan
reviews = ["Produk ini bagus", "Saya suka produk ini", "Kualitasnya sangat buruk", "Layanan cepat dan ramah"]
# Tokenisasi data ulasan
tokenized_reviews = [word_tokenize(review.lower()) for review in reviews]
# Melatih model Word2Vec
model = Word2Vec(tokenized_reviews, vector_size=50, window=3, min_count=1, workers=4)
# Menampilkan vektor kata
print("Vektor untuk kata 'produk':\n", model.wv['produk'])

Vektor untuk kata 'produk':
[-0.01631583  0.0089916  -0.00827415  0.00164907  0.01699724 -0.00892435
  0.009035   -0.01357392 -0.00709698  0.01879702 -0.00315531  0.00064274
 -0.00828126 -0.01536538 -0.00301602  0.00493959 -0.00177605  0.01106732
 -0.00548595  0.00452013  0.01091159  0.01669191 -0.00290748 -0.01841629
  0.0087411   0.00114357  0.01488382 -0.00162657 -0.00527683  0.01750602
 -0.00171311  0.00565313  0.01080286  0.01410531 -0.01140624  0.00371764
  0.01217773 -0.0095961  -0.00621452  0.01359526  0.00326295  0.00037983
  0.00694727  0.00043555  0.01923765  0.01012121 -0.01783478 -0.01408312
  0.00180291  0.01278507]
```

Gambar 10. Proses Word2vec

Keuntungan menggunakan embedding dalam mengatasi keragaman bahasa.

a. Keragaman Bahasa dalam Ulasan Produk E-Commerce

Ulasan produk e-commerce memiliki karakteristik yang sangat beragam, dengan variasi gaya bahasa dan pilihan kata yang mencerminkan perasaan konsumen terhadap produk. Penggunaan bahasa formal, slang, atau bahkan bahasa daerah dalam ulasan menambah kompleksitas analisis sentimen. Dalam konteks ini, model pembelajaran mesin perlu menangkap nuansa semantik kata-kata, meskipun digunakan dalam bentuk atau konteks yang berbeda. Teknik representasi kata tradisional, seperti bag-of-words, tidak mampu menangani keragaman ini, sehingga pendekatan berbasis word embedding, seperti Word2Vec, menawarkan solusi untuk memahami hubungan antar kata dalam berbagai konteks (Mikolov et al., 2013).

b. Keunggulan Word Embedding dalam Mengatasi Keragaman Bahasa

Word2Vec, yang dikembangkan oleh Mikolov et al. (2013), adalah algoritma untuk menghasilkan representasi kata dalam bentuk vektor berdimensi tinggi menggunakan model neural network. Keunggulan utama Word2Vec dibandingkan dengan TF-IDF atau bag-of-words adalah kemampuannya mempertimbangkan konteks kata dalam kalimat. Teknik ini mampu menangkap hubungan semantik antar kata yang memiliki makna serupa meskipun diekspresikan berbeda, seperti "baik" dan "bagus". Word2Vec juga efektif dalam menangani kata-kata yang jarang ditemukan dalam teks, serta variasi dialek dan slang, yang sering ditemui dalam ulasan produk e-commerce (Mikolov et al., 2013).

c. Implementasi Word2Vec dalam Mengatasi Keragaman Bahasa

Implementasi Word2Vec dalam preprocessing untuk analisis sentimen ulasan produk e-commerce dapat dilakukan dengan langkah-langkah berikut. Pertama, data ulasan produk perlu diproses melalui tahap tokenisasi, yaitu memecah teks menjadi unit-unit terkecil (kata atau frasa). Setelah tokenisasi, model Word2Vec dilatih menggunakan data ulasan yang telah diproses. Proses pelatihan ini memungkinkan model untuk belajar tentang konteks kata-kata yang ada dalam kalimat dan membentuk vektor kata yang mencerminkan hubungan semantik antar kata-kata tersebut.

d. Dampak Word2Vec pada Akurasi Model Sentimen

Penggunaan Word2Vec dalam analisis sentimen meningkatkan akurasi model dengan mempertimbangkan konteks kata dalam kalimat. Penelitian menunjukkan bahwa Word2Vec menghasilkan akurasi lebih tinggi dibandingkan TF-IDF atau metode lain, terutama dalam mengidentifikasi sentimen yang tidak diekspresikan secara eksplisit. Word2Vec juga lebih efektif dalam menangani ironi, sindiran, dan ambiguitas, seperti dalam kalimat "Produk ini buruk, tetapi layanan pelanggan sangat baik", yang sulit dianalisis menggunakan TF-IDF.

BAB 7.

Hyperparameter Tuning dalam Pengoptimalan Model

7.1. Definisi Hyperparameter Tuning

Pengertian hyperparameter dalam machine learning.

Dalam pembelajaran mesin, hyperparameter merujuk pada parameter yang ditentukan sebelum pelatihan model dimulai dan tidak dipelajari oleh model selama proses pelatihan. Berbeda dengan parameter model yang dioptimalkan oleh algoritma selama pelatihan, seperti koefisien dalam regresi linier atau bobot dalam jaringan saraf, hyperparameter mengontrol cara kerja algoritma. Hyperparameter ini sangat memengaruhi performa model (Han et al., 2020). Contoh penting adalah dalam algoritma Support Vector Machine (SVM), di mana hyperparameter seperti C dan γ harus diatur dengan tepat. Nilai C mengontrol trade-off antara margin yang lebih besar dan kesalahan klasifikasi, sementara γ mengontrol pengaruh setiap titik data dalam pemisahan kelas (Ardhani, Chamidah, & Saifudin, 2021). Pemilihan hyperparameter yang tepat adalah kunci untuk menghindari masalah overfitting atau underfitting. Pengaturan yang salah dapat menyebabkan model terlalu cocok dengan data pelatihan (overfitting) atau tidak cukup kuat untuk menangkap pola (underfitting). Oleh karena itu, proses hyperparameter tuning, yaitu pencarian nilai optimal hyperparameter, sangat penting untuk memastikan model dapat menggeneralisasi dengan baik pada data uji yang belum terlihat (Ardhani et al., 2021).

Pengertian Hyperparameter Tuning

Hyperparameter tuning adalah proses mencari kombinasi terbaik dari hyperparameter yang digunakan dalam model pembelajaran mesin. Proses ini sangat penting karena pemilihan hyperparameter yang tepat

dapat meningkatkan kinerja model secara signifikan. Meskipun algoritma pembelajaran mesin dapat mempelajari pola dari data, tuning yang tepat dapat mengoptimalkan akurasi model dan mengurangi masalah seperti overfitting atau underfitting (Gandhi, Merikapudi, & Narayana, 2023). Beberapa teknik yang digunakan dalam tuning hyperparameter meliputi GridSearchCV dan RandomizedSearchCV, yang mengeksplorasi berbagai kombinasi nilai hyperparameter. GridSearchCV melakukan pencarian sistematis melalui grid parameter, sementara RandomizedSearchCV mencari kombinasi secara acak (Gandhi et al., 2023). Selain itu, dengan kemajuan teknologi, teknik optimasi berbasis trial-and-error seperti Optuna semakin populer. Optuna menawarkan efisiensi lebih tinggi dalam mencari nilai optimal dengan mengurangi jumlah percobaan yang diperlukan, sehingga mempercepat proses tuning (Nugraha, 2022). Meskipun setiap teknik memiliki kelebihan dan kekurangannya, pemilihan metode tuning yang tepat sangat bergantung pada kompleksitas model dan jumlah hyperparameter yang perlu disesuaikan. Oleh karena itu, tuning hyperparameter memainkan peran penting dalam menghasilkan model yang lebih akurat dan efisien.

Pentingnya tuning untuk meningkatkan akurasi model.

Tuning hyperparameter melibatkan beberapa metode yang memiliki pendekatan berbeda untuk mencari nilai optimal dari hyperparameter. Dua metode yang paling banyak digunakan dalam optimasi hyperparameter adalah *GridSearchCV* dan *RandomizedSearchCV*. Masing-masing memiliki kelebihan dan kekurangan tergantung pada ruang pencarian dan kebutuhan komputasi. Selain itu, dengan kemajuan teknologi, framework optimasi baru seperti *Optuna* semakin banyak digunakan karena kemampuannya untuk melakukan pencarian yang lebih efisien.

a. GridSearchCV

GridSearchCV adalah metode yang paling umum digunakan untuk pencarian hyperparameter yang menyeluruh. Dalam metode ini, pengguna menentukan grid (rangkaiian nilai) untuk setiap hyperparameter yang ingin diuji. *GridSearchCV* kemudian menguji setiap

kombinasi dari nilai-nilai tersebut untuk menemukan kombinasi terbaik. Meskipun sangat efektif, metode ini dapat memakan waktu, terutama ketika ruang parameter sangat besar. Dalam penelitian yang dijelaskan dalam *RevMaster.pdf*, *GridSearchCV* digunakan untuk mengoptimalkan model SVM dalam analisis sentimen ulasan produk e-commerce dengan mencoba beberapa nilai dari parameter C dan γ . Hasil optimasi ini membantu meningkatkan akurasi model secara signifikan.

b. RandomizedSearchCV

Sebagai alternatif yang lebih cepat, *RandomizedSearchCV* menguji kombinasi parameter secara acak. Metode ini lebih efisien dalam hal waktu karena hanya menguji sejumlah kombinasi yang ditentukan oleh pengguna, dibandingkan dengan pencarian menyeluruh yang dilakukan oleh *GridSearchCV*. Metode ini sering digunakan ketika ruang pencarian sangat besar dan waktu menjadi faktor pembatas.

c. Optuna

Optuna adalah framework optimasi yang lebih baru dan lebih efisien. Dengan menggunakan algoritma berbasis *Bayesian Optimization*, *Optuna* dapat melakukan pencarian yang lebih efisien dalam ruang hyperparameter yang besar. Dalam penelitian yang dicontohkan pada penelitian ini, *Optuna* digunakan untuk menemukan kombinasi optimal dari parameter C dan γ dalam model SVM, yang menghasilkan peningkatan akurasi dibandingkan dengan *GridSearchCV* dan *RandomizedSearchCV*.

7.2. Metode Hyperparameter Tuning

GridSearchCV Eksplorasi semua kombinasi parameter.

Dalam pembelajaran mesin, optimasi hyperparameter merupakan langkah penting untuk meningkatkan kinerja model. Salah satu teknik yang umum digunakan untuk optimasi ini adalah *GridSearchCV*. Pada penerapannya untuk model Support Vector Machine (SVM) dalam analisis sentimen ulasan produk e-commerce, *GridSearchCV* melakukan eksplorasi menyeluruh terhadap kombinasi parameter yang digunakan

dalam model, seperti C, gamma, dan kernel. Parameter grid adalah sekumpulan nilai hyperparameter yang diuji untuk menemukan kombinasi terbaik. Parameter C mengontrol regularisasi, gamma mengatur pengaruh titik data, dan kernel menentukan fungsi pemetaan data ke ruang fitur lebih tinggi (Han et al., 2020). Dalam implementasi ini, GridSearchCV diuji menggunakan 3-fold cross-validation untuk menghindari overfitting dan memastikan model dapat menggeneralisasi dengan baik pada data yang tidak terlihat sebelumnya. Setelah proses pencarian optimal selesai, `best_params_` dan `best_score_` menunjukkan kombinasi parameter terbaik dan skor tertinggi yang dicapai (Gandhi et al., 2023). Evaluasi model dilakukan dengan metrik seperti akurasi, precision, recall, dan F1-score, memberikan gambaran lengkap tentang kinerja model. Meskipun proses ini memerlukan waktu dan sumber daya, hasil yang diperoleh sangat penting, terutama dalam analisis sentimen ulasan produk e-commerce yang kompleks.

```
# Import library yang dibutuhkan
import pandas as pd
from sklearn.model_selection import train_test_split, GridSearchCV
from sklearn.svm import SVC
from sklearn.feature_extraction.text import TfidfVectorizer
from sklearn.metrics import accuracy_score, classification_report

# Dataset yang sudah diperbesar (solusi terbaik)
data = {
    'review': [
        'Produk bagus dan cepat sampai',
        'Layanan buruk, produk tidak sesuai',
        'Kualitas oke, harga terjangkau',
        'Pengiriman lambat, produk cacat',
        'Barang sesuai ekspektasi',
        'Sangat puas dengan pembelian ini',
        'Tidak direkomendasikan, kualitas jelek',
        'Cocok dengan harga yang dibayarkan',
        'Kurang memuaskan, tidak akan beli lagi',
        'Sempurna, packing aman dan rapi',
        'Respon penjual cepat dan ramah',
        'Barang rusak saat diterima',
        'Kualitas produk di bawah ekspektasi',
        'Pengiriman tepat waktu, barang oke',
        'Harga murah tapi kualitas premium'
    ],
    'sentimen': ['Positif', 'Negatif', 'Positif', 'Negatif', 'Positif',
                'Positif', 'Negatif', 'Positif', 'Negatif', 'Positif',
                'Positif', 'Negatif', 'Negatif', 'Positif', 'Positif']
}
```

Gambar 11. Dataset untuk GridSearchCV

```

# Membuat DataFrame
df = pd.DataFrame(data)
# Mengubah sentimen menjadi 1 (positif) dan 0 (negatif)
df['sentimen'] = df['sentimen'].map({'Positif': 1, 'Negatif': 0, 'Positif': 1}) # Memastikan semua variasi tertangani
# Preprocessing: Menggunakan TF-IDF untuk representasi teks
vectorizer = TfidfVectorizer()
X = vectorizer.fit_transform(df['review'])
y = df['sentimen']
# Membagi data menjadi data pelatihan dan data pengujian (70:30)
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3, random_state=42)
# Parameter grid untuk GridSearchCV
param_grid = {
    'C': [0.1, 1, 10], # Parameter regularisasi
    'gamma': [0.001, 0.01, 0.1], # Parameter kernel
    'kernel': ['linear', 'rbf'] # Jenis kernel (linear dan RBF)
}
# Membuat model SVM dan menerapkan GridSearchCV dengan 3-fold CV
svm = SVC(probability=True)
grid_search = GridSearchCV(estimator=svm, param_grid=param_grid, cv=3, n_jobs=-1, verbose=1)
# Melatih model dengan GridSearchCV
grid_search.fit(X_train, y_train)
# Menampilkan hasil terbaik dari GridSearchCV
print("\n=== Hasil GridSearchCV ===")
print(f"Parameter Terbaik: {grid_search.best_params_}")
print(f"Skor Validasi Terbaik: {grid_search.best_score_:.4f}")
# Menggunakan model terbaik untuk prediksi pada data uji
best_model = grid_search.best_estimator_
y_pred = best_model.predict(X_test)

```

Gambar 12. Kode Program GridSearchCV

```

# Evaluasi model
accuracy = accuracy_score(y_test, y_pred)
print("\n=== Evaluasi Model ===")
print(f"Akurasi pada Data Uji: {accuracy:.4f}")
print("\nLaporan Klasifikasi:")
print(classification_report(y_test, y_pred))
# Contoh prediksi
sample_reviews = ["Saya suka produk ini", "Buruk sekali kualitasnya"]
sample_X = vectorizer.transform(sample_reviews)
sample_pred = best_model.predict(sample_X)
print("\n=== Contoh Prediksi ===")
for text, pred in zip(sample_reviews, sample_pred):
    print(f"Review: '{text}' -> Sentimen: {'Positif' if pred == 1 else 'Negatif'}")

```

Gambar 13. Kode Program GridSearchCV 2

```

Fitting 3 folds for each of 18 candidates, totalling 54 fits

=== Hasil GridSearchCV ===
Parameter Terbaik: {'C': 0.1, 'gamma': 0.001, 'kernel': 'linear'}
Skor Validasi Terbaik: 0.3889

=== Evaluasi Model ===
Akurasi pada Data Uji: 0.6000

Laporan Klasifikasi:

```

	precision	recall	f1-score	support
0	0.00	0.00	0.00	1
1	0.75	0.75	0.75	4
accuracy			0.60	5
macro avg	0.38	0.38	0.38	5
weighted avg	0.60	0.60	0.60	5

```

=== Contoh Prediksi ===
Review: 'Saya suka produk ini' -> Sentimen: Negatif
Review: 'Buruk sekali kualitasnya' -> Sentimen: Negatif

```

Gambar 14. Output Program GridSearchCV

RandomizedSearchCV Sampling acak untuk efisiensi.

Optimasi hyperparameter adalah langkah penting untuk meningkatkan kinerja model pembelajaran mesin, termasuk dalam penerapan model Support Vector Machine (SVM) untuk analisis sentimen. Salah satu metode efisien adalah RandomizedSearchCV, yang melakukan pencarian acak kombinasi hyperparameter dalam ruang parameter yang lebih besar, memberikan efisiensi lebih tinggi dibandingkan GridSearchCV. Metode ini menguji kombinasi acak parameter seperti C, gamma, dan kernel dalam distribusi yang ditentukan, memungkinkan eksplorasi parameter lebih cepat (Hastie, Tibshirani, & Friedman, 2009). Dalam penelitian ini, RandomizedSearchCV digunakan dengan 10 iterasi pencarian dan 3-fold cross-validation, menghasilkan model dengan kombinasi parameter terbaik yang meningkatkan akurasi dan efisiensi (Nugraha, 2022; Alshari et al., 2020).

```

# Import library yang dibutuhkan
import pandas as pd
from sklearn.model_selection import train_test_split, RandomizedSearchCV
from sklearn.svm import SVC
from sklearn.feature_extraction.text import TfidfVectorizer
from sklearn.metrics import accuracy_score, classification_report
from scipy.stats import loguniform
import numpy as np
# Dataset
data = {
    'review': [
        'Produk bagus dan cepat sampai',
        'Layanan buruk, produk tidak sesuai',
        'Kualitas oke, harga terjangkau',
        'Pengiriman lambat, produk cacat',
        'Barang sesuai ekspektasi',
        'Sangat puas dengan pembelian ini',
        'Tidak direkomendasikan, kualitas jelek',
        'Cocok dengan harga yang dibayarkan',
        'Kurang memuaskan, tidak akan beli lagi',
        'Sempurna, packing aman dan rapi',
        'Respon penjual cepat dan ramah',
        'Barang rusak saat diterima',
        'Kualitas produk di bawah ekspektasi',
        'Pengiriman tepat waktu, barang oke',
        'Harga murah tapi kualitas premium'
    ],
    'sentimen': ['Positif', 'Negatif', 'Positif', 'Negatif', 'Positif',
                 'Positif', 'Negatif', 'Positif', 'Negatif', 'Positif',
                 'Positif', 'Negatif', 'Negatif', 'Positif', 'Positif']
}

```

Gambar 15. Dataset untuk RandomizedSearchCV

```

# Membuat DataFrame
df = pd.DataFrame(data)
# Mengubah sentimen menjadi numerik (1=Positif, 0=Negatif)
df['sentimen'] = df['sentimen'].map({'Positif': 1, 'Negatif': 0})
# TF-IDF Vectorizer
vectorizer = TfidfVectorizer()
X = vectorizer.fit_transform(df['review'])
y = df['sentimen']
# Split data 70:30
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3, random_state=42)
# Parameter distribution untuk RandomizedSearchCV
param_dist = {
    'C': loguniform(1e-3, 100),      # Rentang nilai C
    'gamma': loguniform(1e-4, 1),    # Rentang nilai gamma
    'kernel': ['linear', 'rbf', 'poly'] # Jenis kernel
}
# Membuat model SVM
svm = SVC(probability=True)
# RandomizedSearchCV dengan 10 iterasi
random_search = RandomizedSearchCV(
    svm,
    param_distributions=param_dist,
    n_iter=10,
    cv=3,
    n_jobs=-1,
    verbose=1,
    random_state=42
)

```

Gambar 16. Kode Program RandomizedSearchCV

```

▶ # Training model
print("Memulai training dengan RandomizedSearchCV...")
random_search.fit(X_train, y_train)
# Hasil terbaik
print("\n=== Hasil Terbaik ===")
print("Parameter Terbaik:", random_search.best_params_)
print("Akurasi Validasi:", f"{random_search.best_score_:.4f}")
# Evaluasi
best_model = random_search.best_estimator_
y_pred = best_model.predict(X_test)
print("\n=== Evaluasi pada Test Set ===")
print("Akurasi:", accuracy_score(y_test, y_pred))
print("\nClassification Report:")
print(classification_report(y_test, y_pred))
# Contoh prediksi
sample_reviews = [
    "Saya sangat puas dengan produk ini",
    "Barang datang rusak dan tidak bisa dipakai"
]
sample_X = vectorizer.transform(sample_reviews)
sample_pred = best_model.predict(sample_X)
print("\n=== Contoh Prediksi ===")
for text, pred in zip(sample_reviews, sample_pred):
    print(f"'{text}' -> {'Positif' if pred == 1 else 'Negatif'}")

```

Gambar 17. Kode Program RandomizedSearchCV 2

➡ Memulai training dengan RandomizedSearchCV...
Fitting 3 folds for each of 10 candidates, totalling 30 fits

=== Hasil Terbaik ===
Parameter Terbaik: {'C': np.float64(7.915074397656218), 'gamma': np.float64(0.024400607090817518), 'kernel': 'rbf'}
Akurasi Validasi: 0.3889

=== Evaluasi pada Test Set ===
Akurasi: 0.6

Classification Report:

	precision	recall	f1-score	support
0	0.00	0.00	0.00	1
1	0.75	0.75	0.75	4
accuracy			0.60	5
macro avg	0.38	0.38	0.38	5
weighted avg	0.60	0.60	0.60	5

=== Contoh Prediksi ===
'Saya sangat puas dengan produk ini' -> Negatif
'Barang datang rusak dan tidak bisa dipakai' -> Negatif

Gambar 18. Output Program RandomizedSearchCV

Optuna Pendekatan efisien menggunakan Bayesian optimization.

Optuna merupakan salah satu metode optimasi hyperparameter yang memanfaatkan pendekatan Bayesian Optimization untuk secara efisien mengidentifikasi kombinasi parameter terbaik. Teknik ini mengurangi jumlah percobaan yang diperlukan untuk menemukan solusi optimal, sehingga lebih cepat dan hemat sumber daya dibandingkan dengan metode lain seperti GridSearchCV dan RandomizedSearchCV (Bergstra et al., 2011). Bayesian Optimization dalam Optuna bekerja dengan memodelkan fungsi objektif secara probabilistik, yang dalam konteks SVM adalah akurasi model pada data pelatihan. Dengan menggunakan informasi dari percobaan sebelumnya, Optuna memilih nilai parameter yang lebih menjanjikan pada iterasi berikutnya, memungkinkan pencarian yang lebih cerdas dalam ruang parameter.

Salah satu fitur utama Optuna adalah penggunaan Tree-structured Parzen Estimator (TPE) sebagai sampler. Teknik ini memungkinkan pencarian parameter yang lebih efisien dengan memilih nilai yang lebih menjanjikan berdasarkan distribusi probabilistik. Sebagai contoh, dalam eksperimen ini, parameter seperti C , gamma, kernel, dan degree dioptimalkan menggunakan Optuna dengan TPE, yang memungkinkan pencarian lebih cepat dibandingkan metode pencarian grid yang lebih komputasional (Bergstra et al., 2011). Selain efisiensi waktu, Optuna juga menggunakan teknik cross-validation, seperti 3-fold cross-validation, untuk memastikan model dapat menggeneralisasi dengan baik pada data yang tidak terlihat, sehingga mengurangi risiko overfitting.

Setelah optimasi selesai, Optuna memberikan parameter terbaik dan nilai terbaik berdasarkan skor validasi silang yang dihasilkan. Parameter terbaik ini digunakan untuk melatih model SVM dan diuji pada data uji untuk menghasilkan akurasi dan laporan klasifikasi. Penggunaan Optuna dalam optimasi hyperparameter memungkinkan peningkatan akurasi model, menghemat waktu pelatihan, dan menjadikan Optuna pilihan tepat dalam analisis sentimen ulasan produk e-commerce yang melibatkan dataset besar dan kompleks.

```

▶ # Import library yang dibutuhkan
import pandas as pd
from sklearn.model_selection import train_test_split
from sklearn.svm import SVC
from sklearn.feature_extraction.text import TfidfVectorizer
from sklearn.metrics import accuracy_score, classification_report
import numpy as np
import optuna
from optuna.samplers import TPESampler
from sklearn.model_selection import cross_val_score

# Dataset
data = {
    'review': [
        'Produk bagus dan cepat sampai',
        'Layanan buruk, produk tidak sesuai',
        'Kualitas oke, harga terjangkau',
        'Pengiriman lambat, produk cacat',
        'Barang sesuai ekspektasi',
        'Sangat puas dengan pembelian ini',
        'Tidak direkomendasikan, kualitas jelek',
        'Cocok dengan harga yang dibayarkan',
        'Kurang memuaskan, tidak akan beli lagi',
        'Sempurna, packing aman dan rapi',
        'Respon penjual cepat dan ramah',
        'Barang rusak saat diterima',
        'Kualitas produk di bawah ekspektasi',
        'Pengiriman tepat waktu, barang oke',
        'Harga murah tapi kualitas premium'
    ],
    'sentimen': ['Positif', 'Negatif', 'Positif', 'Negatif', 'Positif',
                 'Positif', 'Negatif', 'Positif', 'Negatif', 'Positif',
                 'Positif', 'Negatif', 'Negatif', 'Positif', 'Positif']
}

```

Gambar 19. Dataset untuk Optuna

```

# Membuat DataFrame
df = pd.DataFrame(data)

# Mengubah sentimen menjadi numerik (1=Positif, 0=Negatif)
df['sentimen'] = df['sentimen'].map({'Positif': 1, 'Negatif': 0})

# TF-IDF Vectorizer
vectorizer = TfidfVectorizer()
X = vectorizer.fit_transform(df['review'])
y = df['sentimen']

# Split data 70:30
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3, random_state=42)

# Definisi objective function untuk Optuna
def objective(trial):
    # Parameter yang akan dioptimasi
    params = {
        'C': trial.suggest_float('C', 1e-3, 100, log=True),
        'gamma': trial.suggest_float('gamma', 1e-4, 1, log=True),
        'kernel': trial.suggest_categorical('kernel', ['linear', 'rbf', 'poly']),
        'degree': trial.suggest_int('degree', 2, 5) if trial.params['kernel'] == 'poly' else 3
    }

    # Membuat model SVM dengan parameter yang diuji
    model = SVC(**params)

    # Evaluasi dengan cross-validation
    score = cross_val_score(model, X_train, y_train, cv=3, scoring='accuracy')

    # Mengembalikan akurasi rata-rata
    return score.mean()

# Membuat study Optuna dengan sampler TPE (Bayesian Optimization)
sampler = TPESampler(seed=42)
study = optuna.create_study(direction='maximize', sampler=sampler)

# Menjalankan optimasi
print("Memulai optimasi dengan Optuna (Bayesian Optimization)...")
study.optimize(objective, n_trials=20)

```

Gambar 20. Kode Program Optuna

```

# Hasil terbaik
print("\n=== Hasil Optimasi ===")
print("Nilai Akurasi Terbaik:", study.best_value)
print("Parameter Terbaik:")
for key, value in study.best_params.items():
    print(f"{key}: {value}")
# Melatih model dengan parameter terbaik
best_params = study.best_params
best_model = SVC(**best_params)
best_model.fit(X_train, y_train)
# Evaluasi pada test set
y_pred = best_model.predict(X_test)
accuracy = accuracy_score(y_test, y_pred)
print("\n=== Evaluasi pada Test Set ===")
print("Akurasi:", accuracy)
print("\nClassification Report:")
print(classification_report(y_test, y_pred))
# Contoh prediksi
sample_reviews = [
    "Saya tidak puas dengan produk ini",
    "Barang datang rusak dan tidak bisa dipakai",
    "Kualitas biasa saja tapi harganya murah"
]
sample_X = vectorizer.transform(sample_reviews)
sample_pred = best_model.predict(sample_X)

print("\n=== Contoh Prediksi ===")
for text, pred in zip(sample_reviews, sample_pred):
    print(f"'{text}' -> {'Positif' if pred == 1 else 'Negatif'}")

# Visualisasi hasil optimasi (hanya bekerja di notebook)
try:
    optuna.visualization.plot_optimization_history(study)
except:
    print("\nUntuk visualisasi, jalankan di Google Colab dengan menginstall plotly:")
    print("!pip install plotly")

```

Gambar 21. Kode Program Optuna 2

```

=== Hasil Optimasi ===
Nilai Akurasi Terbaik: 0.38888888888888884
Parameter Terbaik:
C: 0.0745934328572655
gamma: 0.6351221010640696
kernel: linear

=== Evaluasi pada Test Set ===
Akurasi: 0.6

Classification Report:

```

	precision	recall	f1-score	support
0	0.00	0.00	0.00	1
1	0.75	0.75	0.75	4
accuracy			0.60	5
macro avg	0.38	0.38	0.38	5
weighted avg	0.60	0.60	0.60	5

```

=== Contoh Prediksi ===
'Saya tidak puas dengan produk ini' -> Negatif
'Barang datang rusak dan tidak bisa dipakai' -> Negatif
'Kualitas biasa saja tapi harganya murah' -> Positif

```


Gambar 22. Output Program Optuna

7.3. Penerapan Hyperparameter Tuning pada Model SVM

Penggunaan GridSearchCV, RandomizedSearchCV, dan Optuna untuk model SVM.


1. GridSearchCV pada Model SVM

GridSearchCV merupakan metode pencarian parameter yang sistematis dan exhaustif. Teknik ini mengevaluasi semua kombinasi parameter yang mungkin di dalam ruang pencarian yang telah ditentukan sebelumnya. Dengan menggunakan GridSearchCV, kita dapat memastikan bahwa konfigurasi terbaik dari parameter yang digunakan dapat ditemukan, sehingga menghasilkan model dengan performa yang lebih optimal. Berdasarkan data pada dokumen yang diunggah, GridSearchCV digunakan untuk mengoptimasi parameter-parameter penting pada model SVM yang diwakili oleh parameter C dan gamma, serta kernel yang digunakan dalam model. Pada hasil eksperimen dengan TF-IDF + SVM yang dioptimasi menggunakan GridSearchCV, Confusion Matrix yang dihasilkan menunjukkan akurasi model sebesar 84.73%. Meskipun ada sedikit peningkatan dibandingkan dengan model tanpa tuning, model ini masih memiliki beberapa kesalahan klasifikasi pada kedua kelas (positif dan negatif). Secara keseluruhan, hasil ini menunjukkan bahwa GridSearchCV dapat memberikan stabilitas klasifikasi yang cukup baik meskipun tidak sebaik teknik RandomizedSearchCV atau Optuna



Gambar 21. *Confusion Matrix - TFIDF SVM GridSearchCV*

Gambar 21. Confusion Matrix - TFIDF SVM GridSearchCV menunjukkan hasil klasifikasi dari model yang dioptimasi menggunakan GridSearchCV. Dapat dilihat bahwa model ini mengklasifikasikan 377 data negatif (label 0) dan 361 data positif (label 1) dengan benar, namun masih ada beberapa kesalahan klasifikasi, baik positif yang diklasifikasikan sebagai negatif maupun sebaliknya. Confusion Matrix pada Gambar 21 menunjukkan keseimbangan yang cukup baik dalam prediksi antara kedua kelas, namun ada beberapa kesalahan klasifikasi pada kedua kelas, yang menandakan adanya ruang untuk perbaikan lebih lanjut.




Gambar 22. ROC Curve TF-IDF SVM GridSearchCV

Gambar 22. ROC Curve - TFIDF SVM GridSearchCV menunjukkan AUC sebesar 0.92, yang menandakan performa yang sangat baik dalam membedakan antara kelas positif dan negatif.

2. RandomizedSearchCV pada Model SVM


Berbeda dengan GridSearchCV yang mencoba semua kombinasi parameter secara exhaustif, RandomizedSearchCV menggunakan pendekatan yang lebih efisien dengan memilih sejumlah kombinasi parameter secara acak dari ruang pencarian yang lebih besar. Ini memungkinkan pencarian parameter terbaik dilakukan dengan lebih cepat, meskipun mungkin tidak selalu menemukan kombinasi terbaik. Berdasarkan hasil eksperimen yang dijelaskan dalam dokumen yang

diunggah, penggunaan RandomizedSearchCV pada model TF-IDF + SVM memberikan akurasi sebesar 85.88%, yang lebih baik dibandingkan dengan model yang menggunakan GridSearchCV. Pada hasil evaluasi model TF-IDF + SVM + RandomizedSearchCV, Confusion Matrix menunjukkan pengurangan jumlah kesalahan klasifikasi, khususnya pada data negatif yang lebih sering diklasifikasikan dengan benar sebagai negatif. ROC Curve dengan AUC sebesar 0.93 menunjukkan bahwa model ini sangat baik dalam membedakan kelas positif dan negatif.



Gambar 23. Confusion Matrix TF-IDF SVM RandomSearch

Gambar 23. Confusion Matrix - TFIDF SVM RandomSearch menunjukkan pengurangan kesalahan klasifikasi pada model TF-IDF + SVM yang telah dioptimasi dengan RandomizedSearchCV, dengan distribusi yang lebih baik antara kedua kelas. dan menunjukkan hasil klasifikasi yang lebih baik setelah dilakukan tuning parameter secara acak.




Gambar 24. ROC Curve TF-IDF SVM RandomSearch

Gambar 24. ROC Curve TFI DF SVM RandomSearch dengan AUC yang tinggi mendukung kesimpulan bahwa RandomizedSearchCV telah berhasil meningkatkan performa model dalam membedakan sentimen positif dan negatif.


3. Optuna pada Model SVM

Optuna adalah teknik tuning berbasis algoritma Bayesian optimization yang dapat secara efisien mengeksplorasi ruang parameter untuk menemukan kombinasi terbaik dari parameter-parameter yang ada. Optuna menggunakan pendekatan sampling cerdas yang dapat memilih parameter yang optimal secara iteratif berdasarkan trial sebelumnya. Pada model TF-IDF + SVM yang dioptimasi menggunakan Optuna, eksperimen menghasilkan akurasi tertinggi sebesar 86.68%, yang menunjukkan bahwa Optuna mampu menghasilkan model dengan generalisasi yang lebih baik dibandingkan dengan GridSearchCV dan RandomizedSearchCV. Berdasarkan Gambar 25 dan Gambar 26 yang terdapat dalam dokumen yang diunggah, Confusion Matrix dan ROC Curve menunjukkan bahwa Optuna sangat efektif dalam mengurangi kesalahan klasifikasi dan meningkatkan AUC menjadi 0.93.



Gambar 25. Confusion Matrix TF-IDF SVM Optuna

Gambar 25. Confusion Matrix - TFIDF SVM Optuna menunjukkan bahwa model yang dioptimasi menggunakan Optuna dapat memprediksi dengan sangat baik 394 data negatif dan 361 data positif, dengan kesalahan klasifikasi yang lebih kecil dibandingkan dengan teknik tuning lainnya. Dan menunjukkan bahwa Optuna berhasil mengurangi kesalahan klasifikasi pada model SVM yang dioptimasi dengan metode Bayesian Optimization, menghasilkan model yang lebih stabil.



Gambar 26. ROC Curve TF-IDF SVM Optuna

Gambar 26. ROC Curve TF-IDF SVM Optuna menunjukkan AUC sebesar 0.93, yang mengindikasikan bahwa model yang dioptimasi dengan Optuna memiliki kemampuan prediksi yang sangat baik.

Penerapan hyperparameter tuning menggunakan GridSearchCV, RandomizedSearchCV, dan Optuna menunjukkan hasil yang sangat berbeda dalam meningkatkan performa model SVM. Berdasarkan evaluasi yang dilakukan GridSearchCV memberikan hasil yang stabil dengan akurasi sekitar 84.73%, namun memiliki beberapa kesalahan klasifikasi yang signifikan pada kedua kelas. RandomizedSearchCV menghasilkan model dengan akurasi 85.88%, menunjukkan keefektifan metode ini dalam meningkatkan performa SVM dalam waktu yang lebih efisien. Optuna, yang menggunakan Bayesian optimization, memberikan hasil terbaik dengan akurasi mencapai 86.68%, serta mengurangi kesalahan klasifikasi secara signifikan. Secara keseluruhan, Optuna memberikan hasil yang lebih unggul dalam meningkatkan akurasi dan stabilitas model, menjadikannya pilihan terbaik untuk optimasi parameter pada model SVM, terutama untuk aplikasi analisis sentimen berbasis teks.

Pengaruh tuning terhadap performa model.

Tuning hyperparameter memainkan peran krusial dalam meningkatkan performa model klasifikasi, khususnya pada Support Vector Machine (SVM). Berdasarkan pembahasan yang terdapat dalam dokumen ini, penerapan teknik tuning seperti GridSearchCV, RandomizedSearchCV, dan Optuna terbukti memiliki dampak signifikan terhadap akurasi model dan kemampuan generalisasi dalam tugas analisis sentimen. Pada model TF-IDF + SVM yang menggunakan GridSearchCV, pengaruh tuning terlihat pada peningkatan stabilitas dan akurasi klasifikasi. Meskipun tidak menghasilkan perubahan yang sangat drastis, GridSearchCV berhasil mencapai akurasi sebesar 84.73% (Gambar 21). Namun, masih terdapat kesalahan klasifikasi, baik untuk kelas negatif maupun positif, yang menunjukkan bahwa meskipun tuning parameter meningkatkan stabilitas model, optimasi lebih lanjut diperlukan. Gambar 22 yang menunjukkan ROC Curve dengan nilai AUC 0.92 memperlihatkan bahwa model memiliki kemampuan diskriminasi yang cukup tinggi, tetapi belum mencapai performa optimal.

Sebaliknya, penerapan RandomizedSearchCV dalam eksperimen TF-IDF + SVM menghasilkan akurasi lebih baik, yaitu 85.88%, dengan pengurangan kesalahan klasifikasi pada kedua kelas (Gambar 23). Hal ini

mengindikasikan bahwa pencarian acak lebih efisien dalam menemukan kombinasi parameter yang optimal tanpa mengorbankan waktu. ROC Curve (Gambar 24) yang menunjukkan nilai AUC sebesar 0.93 mengonfirmasi kemampuan model dalam membedakan antara kelas positif dan negatif secara efektif. Penerapan Optuna sebagai metode Bayesian Optimization pada model TF-IDF + SVM memberikan hasil yang paling signifikan, dengan akurasi tertinggi mencapai 86.68%. Optuna tidak hanya mengurangi kesalahan klasifikasi, tetapi juga meningkatkan kemampuan model untuk menggeneralisasi dengan lebih baik (Gambar 25 dan Gambar 26). Nilai AUC yang tetap di angka 0.93 menunjukkan bahwa Optuna secara efisien mengeksplorasi ruang parameter dan memberikan solusi yang lebih optimal dibandingkan metode lain.

BAB 8

Evaluasi Model Sentimen

8.1. Metrik Evaluasi dalam Klasifikasi Sentimen

Akurasi, Precision, Recall, F1-Score, Dan Confusion Matrix.

Metrik evaluasi dalam klasifikasi sentimen adalah alat penting untuk menilai kinerja model dalam mengklasifikasikan data teks, terutama dalam konteks analisis sentimen. Dalam penelitian ini, beberapa metrik utama yang digunakan adalah akurasi, precision, recall, F1-score, dan confusion matrix. Metrik-metrik ini memberikan gambaran yang komprehensif tentang efektivitas model dalam mengidentifikasi sentimen positif dan negatif. Akurasi adalah rasio antara jumlah prediksi yang benar dan total jumlah data. Dalam konteks model Word2Vec + SVM yang dituning dengan RandomizedSearchCV, akurasi tercatat sebesar 84.39%

	precision	recall	f1-score	support
0	0.82	0.88	0.85	428
1	0.88	0.81	0.84	443
accuracy			0.84	871
macro avg	0.85	0.84	0.84	871
weighted avg	0.85	0.84	0.84	871

Accuracy : 0.8438576349024111

Gambar 27. Word2Vec SVM RandomizedSearchCV

Gambar 27. Word2Vec SVM RandomizedSearchCV. Angka ini menunjukkan bahwa model mampu mengklasifikasikan dengan benar sebagian besar data uji, tetapi tidak memberikan informasi lengkap mengenai keseimbangan antara kelas positif dan negatif. Oleh karena itu, akurasi saja tidak cukup untuk menilai kinerja model, terutama dalam situasi di mana kelas tidak seimbang.

Precision mengukur proporsi prediksi positif yang benar dari seluruh prediksi positif yang dibuat. Dalam laporan klasifikasi untuk kelas negatif (label 0), precision tercatat 0.82, sementara untuk kelas positif (label 1),

precision adalah 0.87. Ini menunjukkan bahwa model cukup baik dalam menghindari false positives, yaitu ketika model mengklasifikasikan data negatif sebagai positif. Precision yang tinggi sangat penting dalam konteks analisis sentimen, di mana kesalahan klasifikasi negatif sebagai positif dapat memiliki konsekuensi signifikan.


Recall, di sisi lain, mengukur kemampuan model untuk mengidentifikasi semua contoh positif dalam data. Recall untuk kelas negatif adalah 0.88 dan untuk kelas positif adalah 0.81. Hal ini menunjukkan bahwa meskipun model berhasil mengenali sebagian besar contoh negatif, ada beberapa contoh positif yang terlewatkan. Keseimbangan antara precision dan recall sangat penting, dan metrik F1-score, yang merupakan rata-rata harmonis dari precision dan recall, memberikan gambaran yang lebih menyeluruh. F1-score untuk kelas negatif adalah 0.85, sedangkan untuk kelas positif adalah 0.84, menunjukkan bahwa model memiliki keseimbangan yang baik dalam klasifikasi kedua kelas.

	precision	recall	f1-score	support
0	0.81	0.88	0.84	441
1	0.87	0.79	0.83	430
accuracy			0.84	871
macro avg	0.84	0.84	0.84	871
weighted avg	0.84	0.84	0.84	871

Accuracy : 0.835820895522388

Gambar 28. Classification Report Word2Vec SVM GridSearch.


Confusion matrix adalah alat visual yang menunjukkan bagaimana model mengklasifikasikan data. Dalam model Word2Vec + SVM yang dituning menggunakan GridSearchCV, confusion matrix menunjukkan bahwa dari 871 data uji, model berhasil mengklasifikasikan 389 data negatif dan 339 data positif dengan benar. Namun, terdapat 52 kesalahan klasifikasi negatif sebagai positif dan 91 kesalahan sebaliknya. Ini menunjukkan bahwa meskipun model menunjukkan kinerja yang baik, masih ada ruang untuk perbaikan dalam mengurangi kesalahan klasifikasi.



Gambar 29. Confusion matrix Word2Vec SVM GridSearchCV

Pentingnya tuning hyperparameter juga ditekankan dalam analisis ini. Proses tuning menggunakan metode seperti RandomizedSearchCV dan GridSearchCV terbukti meningkatkan kinerja model secara signifikan. Misalnya, model yang dituning dengan RandomizedSearchCV menunjukkan peningkatan akurasi hingga 85.88% dan F1-score yang lebih baik dibandingkan model tanpa tuning. Hal ini menunjukkan bahwa pemilihan parameter yang tepat dapat meningkatkan kemampuan klasifikasi model secara substansial.

Sebagai tambahan, ROC curve (Receiver Operating Characteristic) dan nilai AUC (Area Under Curve) memberikan informasi lebih lanjut tentang kinerja model. Model yang dituning dengan GridSearchCV menunjukkan AUC sebesar 0.92, yang mencerminkan kemampuan model untuk membedakan antara kelas positif dan negatif dengan baik. Nilai AUC yang tinggi menunjukkan bahwa model memiliki sensitivitas dan spesifisitas yang baik, yang merupakan indikator penting dalam evaluasi model klasifikasi.



Gambar 30. ROC Curve Word2Vec SVM GridSearchCV

Pentingnya Metrik Berbasis Kelas Untuk Menangani Ketidakseimbangan Kelas.

Metrik evaluasi dalam klasifikasi sentimen sangat penting, terutama ketika berhadapan dengan ketidakseimbangan kelas. Dalam konteks ini, metrik berbasis kelas seperti precision, recall, dan F1-score menjadi krusial untuk memahami kinerja model secara menyeluruh. Ketidakseimbangan kelas sering terjadi dalam dataset analisis sentimen, di mana jumlah data positif dan negatif tidak sebanding. Oleh karena itu, penggunaan metrik yang mempertimbangkan distribusi kelas sangat diperlukan untuk memberikan gambaran akurat tentang kemampuan model dalam mengklasifikasikan data.

Dalam penelitian ini, model Word2Vec + SVM yang dituning dengan RandomizedSearchCV menunjukkan akurasi sebesar 84.39%. Laporan klasifikasi (Gambar 27) mengungkapkan bahwa untuk kelas negatif (label 0), precision tercatat 0.82, recall 0.88, dan F1-score 0.85. Sementara untuk kelas positif (label 1), precision adalah 0.87, recall 0.81, dan F1-score 0.84. Nilai rata-rata (macro dan weighted avg) mencapai 0.85, menunjukkan bahwa model ini mampu mempertahankan keseimbangan antara kelas positif dan negatif. Hal ini penting, karena model yang hanya

mengandalkan akurasi global bisa memberikan hasil yang menyesatkan jika kelas yang lebih besar mendominasi.

Confusion matrix (Gambar 29) menunjukkan bahwa dari 871 data uji, model berhasil mengklasifikasikan 389 data negatif dan 339 data positif dengan benar, sementara terdapat 52 kesalahan klasifikasi negatif sebagai positif dan 91 kesalahan sebaliknya. Ini menandakan bahwa meskipun model cukup baik dalam mengidentifikasi kelas negatif, masih ada ruang untuk perbaikan dalam mengurangi kesalahan klasifikasi. Oleh karena itu, analisis lebih dalam terhadap precision dan recall menjadi penting, terutama dalam konteks aplikasi nyata di mana kesalahan klasifikasi dapat memiliki dampak signifikan.

Penggunaan metrik berbasis kelas seperti precision dan recall membantu dalam mengidentifikasi kekuatan dan kelemahan model. Precision yang tinggi untuk kelas positif menunjukkan bahwa ketika model memprediksi positif, ia cenderung benar. Namun, recall yang lebih rendah untuk kelas positif (0.81) menunjukkan bahwa ada sejumlah data positif yang terlewatkan. Hal ini berimplikasi pada pentingnya meningkatkan recall untuk kelas positif, yang dapat dicapai dengan melakukan tuning lebih lanjut pada model atau menggunakan teknik yang lebih kompleks.

ROC curve (Gambar 28) dengan AUC sebesar 0.92 menunjukkan bahwa model memiliki kemampuan diskriminasi yang baik dalam membedakan antara kelas positif dan negatif. AUC yang tinggi menunjukkan bahwa model tidak hanya mampu mendeteksi dengan baik tetapi juga meminimalkan kesalahan klasifikasi. Ini sangat penting dalam konteks analisis sentimen, di mana kemampuan untuk membedakan antara sentimen positif dan negatif dengan akurasi tinggi adalah kunci untuk aplikasi yang efektif.

Dalam konteks ketidakseimbangan kelas, penting untuk tidak hanya fokus pada akurasi tetapi juga memperhatikan metrik berbasis kelas. Penggunaan F1-score sebagai metrik utama memberikan gambaran yang lebih seimbang mengenai kinerja model, terutama ketika kelas positif dan negatif memiliki proporsi yang tidak seimbang. F1-score yang baik menunjukkan bahwa model tidak hanya akurat tetapi juga mampu

menangkap pola yang relevan dalam data, sehingga membuatnya lebih dapat diandalkan dalam situasi nyata.

Secara keseluruhan, metrik berbasis kelas sangat penting dalam menangani ketidakseimbangan kelas dalam klasifikasi sentimen. Dengan mengandalkan metrik seperti precision, recall, dan F1-score, peneliti dapat memperoleh wawasan yang lebih dalam tentang kinerja model dan melakukan perbaikan yang diperlukan untuk meningkatkan akurasi klasifikasi. Dalam penelitian ini, kombinasi Word2Vec dan SVM, terutama ketika ditunjang dengan teknik tuning yang tepat, menunjukkan potensi yang kuat dalam analisis sentimen, meskipun masih ada tantangan yang perlu diatasi untuk mencapai performa optimal.

8.2. Hasil Pengujian Model

Perbandingan akurasi dan performa model yang menggunakan TF-IDF dan Word2Vec.


Hasil pengujian model klasifikasi sentimen dengan menggunakan TF-IDF dan Word2Vec menunjukkan perbedaan yang signifikan dalam akurasi dan performa. Dalam penelitian ini, dua pendekatan utama dievaluasi: TF-IDF + SVM dan Word2Vec + SVM, masing-masing dengan dan tanpa optimasi hyperparameter. Berdasarkan laporan klasifikasi yang disajikan, model TF-IDF + SVM tanpa tuning menghasilkan akurasi sebesar 84.38%, dengan nilai precision dan recall yang cukup seimbang untuk kedua kelas

	precision	recall	f1-score	support
0	0.84	0.86	0.85	449
1	0.85	0.82	0.84	422
accuracy			0.84	871
macro avg	0.84	0.84	0.84	871
weighted avg	0.84	0.84	0.84	871

Accuracy : 0.8438576349024111


Gambar 31. Classification Report - TFIDF SVM

Gambar 31. Classification Report - TFIDF SVM Precision untuk kelas negatif (label 0) tercatat 0.84, sedangkan untuk kelas positif (label 1) mencapai 0.85. Hal ini menunjukkan bahwa model TF-IDF mampu menangkap pola bahasa dalam ulasan produk dengan baik, menjadikannya sebagai baseline yang solid untuk perbandingan lebih lanjut. Di sisi lain, model Word2Vec + SVM tanpa tuning menunjukkan akurasi yang lebih rendah, yaitu 80.71%, dengan precision dan recall yang juga lebih rendah dibandingkan dengan TF-IDF



Gambar 32. ROC Curve - TFIDF SVM Random search

Gambar 32. ROC Curve - TFIDF SVM Random search F1-score untuk kelas negatif adalah 0.81, sedangkan untuk kelas positif adalah 0.80. Hasil ini mengindikasikan bahwa meskipun Word2Vec memiliki potensi dalam menangkap konteks semantik antar kata, tanpa tuning yang tepat, performanya tidak sebanding dengan TF-IDF. AUC pada ROC Curve untuk model Word2Vec tercatat 0.89, menunjukkan bahwa meskipun model memiliki kemampuan diskriminasi yang baik, masih ada ruang untuk perbaikan



Gambar 33. ROC Curve - Word2Vec SVM

Ketika dilakukan optimasi hyperparameter, model Word2Vec + SVM dengan RandomizedSearchCV menunjukkan peningkatan akurasi menjadi 84.39%, mendekati performa TF-IDF

	precision	recall	f1-score	support
0	0.80	0.82	0.81	439
1	0.82	0.79	0.80	432
accuracy			0.81	871
macro avg	0.81	0.81	0.81	871
weighted avg	0.81	0.81	0.81	871

Accuracy : 0.8071182548794489

Gambar 34. Classification Report - Word2Vec SVM

Gambar 34. Classification Report - Word2Vec SVM. Metrik evaluasi menunjukkan bahwa model ini dapat mengurangi kesalahan klasifikasi, dengan AUC meningkat menjadi 0.92 pada ROC Curve, yang menandakan kemampuan diskriminasi yang lebih baik dalam membedakan kelas positif dan negatif. Hal ini menunjukkan bahwa tuning parameter seperti C dan gamma melalui RandomizedSearchCV sangat berpengaruh terhadap kinerja model.

Sebaliknya, model TF-IDF + SVM yang dioptimalkan dengan RandomizedSearchCV mencatatkan akurasi tertinggi sebesar 85.88%, dengan AUC pada ROC Curve mencapai 0.93 (Gambar 32). Nilai-nilai ini menunjukkan bahwa model ini tidak hanya akurat tetapi juga stabil dalam klasifikasi, dengan metrik yang seimbang antara precision dan recall. Hasil ini menunjukkan bahwa TF-IDF, ketika dipadukan dengan teknik tuning yang tepat, dapat memberikan performa yang lebih baik dibandingkan dengan Word2Vec, bahkan setelah optimasi.

Dalam konteks perbandingan kedua metode, TF-IDF terbukti lebih unggul dalam hal akurasi dan kemampuan diskriminasi, terutama ketika dikombinasikan dengan teknik tuning yang efisien. Meskipun Word2Vec memiliki keunggulan dalam menangkap konteks semantik, hasilnya masih belum mampu mengalahkan performa TF-IDF. Namun, dengan tuning yang tepat, Word2Vec tetap dapat bersaing dan memberikan hasil yang layak, terutama dalam aplikasi yang memerlukan pemahaman konteks yang lebih dalam.

Secara keseluruhan, hasil pengujian menunjukkan bahwa pemilihan metode representasi fitur dan strategi tuning sangat mempengaruhi performa model klasifikasi sentimen. Model TF-IDF + SVM dengan optimasi menunjukkan hasil yang lebih baik dibandingkan Word2Vec + SVM, baik dalam hal akurasi maupun kemampuan diskriminasi, menjadikannya pilihan yang lebih solid untuk aplikasi analisis sentimen berbasis teks.

Dampak optimasi hyperparameter terhadap hasil klasifikasi sentimen.

Hasil pengujian model klasifikasi sentimen menunjukkan dampak signifikan dari optimasi hyperparameter terhadap kinerja model, baik untuk pendekatan TF-IDF maupun Word2Vec. Dalam penelitian ini, beberapa teknik tuning seperti RandomizedSearchCV, GridSearchCV, dan Optuna diterapkan untuk meningkatkan akurasi model. Model dasar (tanpa tuning) menggunakan TF-IDF + SVM mencapai akurasi sebesar 84.38% dengan nilai AUC (Area Under Curve) pada ROC Curve sebesar 0.93, menunjukkan kemampuan klasifikasi yang baik (Gambar 31 dan

Gambar 21). Namun, performa ini dapat ditingkatkan lebih lanjut dengan penerapan teknik tuning.

Ketika menggunakan RandomizedSearchCV pada model TF-IDF + SVM, akurasi meningkat menjadi 85.88%, dengan AUC tetap pada 0.93. Hasil ini menunjukkan bahwa optimasi parameter, seperti C dan gamma, secara signifikan meningkatkan kemampuan model dalam mengidentifikasi kelas positif dan negatif. Precision untuk kelas negatif meningkat menjadi 0.83, dan recall menjadi 0.91, yang menunjukkan bahwa model lebih baik dalam mendeteksi data positif (Gambar 35). Tuning hyperparameter juga mengurangi jumlah kesalahan klasifikasi, yang tercermin dalam confusion matrix, di mana kesalahan klasifikasi ke positif dan negatif menurun.

	precision	recall	f1-score	support
0	0.83	0.91	0.87	445
1	0.89	0.81	0.85	426
accuracy			0.86	871
macro avg	0.86	0.86	0.86	871
weighted avg	0.86	0.86	0.86	871

Accuracy : 0.8587830080367393

Gambar 35. Classification Report TFIDF SVM Random search

Selain itu, penerapan GridSearchCV pada model TF-IDF + SVM memberikan hasil yang cukup baik dengan akurasi 84.73% dan AUC 0.92

	precision	recall	f1-score	support
0	0.83	0.87	0.85	435
1	0.86	0.83	0.84	436
accuracy			0.85	871
macro avg	0.85	0.85	0.85	871
weighted avg	0.85	0.85	0.85	871

Accuracy : 0.8473019517795637

Gambar 36. Classification Report - TFIDF SVM GridSearchCV

(Gambar 36 dan Gambar 22). Meskipun hasil ini sedikit lebih rendah dibandingkan RandomizedSearchCV, GridSearchCV memberikan jaminan terhadap konsistensi hasil. Dengan mengevaluasi semua kombinasi parameter yang mungkin, GridSearchCV mampu menemukan konfigurasi optimal yang meningkatkan stabilitas dan akurasi model. Hasil evaluasi menunjukkan bahwa model ini dapat diandalkan dalam aplikasi analisis sentimen meskipun performanya tidak sebaik yang diperoleh dari RandomizedSearchCV.

Di sisi lain, untuk model Word2Vec + SVM yang dituning menggunakan RandomizedSearchCV, terjadi peningkatan akurasi menjadi 84.39% dengan AUC sebesar 0.91.

	precision	recall	f1-score	support
0	0.82	0.88	0.85	428
1	0.88	0.81	0.84	443
accuracy			0.84	871
macro avg	0.85	0.84	0.84	871
weighted avg	0.85	0.84	0.84	871

Accuracy : 0.8438576349024111

Gambar 37. Classification Report - Word2Vec SVM
RandomizedSearchCV

Gambar 37. Classification Report - Word2Vec SVM RandomizedSearchCV. Meskipun hasil ini masih di bawah TF-IDF, peningkatan performa menunjukkan pentingnya optimasi parameter dalam meningkatkan klasifikasi. Confusion matrix menunjukkan bahwa model mampu mengurangi kesalahan klasifikasi, yang berarti bahwa tuning hyperparameter membantu dalam meningkatkan kemampuan model dalam membedakan antara kelas positif dan negatif.

Penerapan Optuna sebagai metode tuning hyperparameter pada model TF-IDF + SVM menghasilkan akurasi tertinggi sebesar 86.68%.

	precision	recall	f1-score	support
0	0.84	0.84	0.84	442
1	0.83	0.84	0.84	429
accuracy			0.84	871
macro avg	0.84	0.84	0.84	871
weighted avg	0.84	0.84	0.84	871

Accuracy : 0.8381171067738232

Gambar 38. Classification Report - TF-IDF SVM Optuna.

Dengan pendekatan Bayesian optimization, Optuna dapat menyesuaikan parameter secara adaptif dan efisien, meningkatkan performa klasifikasi secara keseluruhan. Nilai AUC yang tinggi sebesar 0.93 menegaskan bahwa model ini memiliki kemampuan diskriminasi yang sangat baik. Hasil ini menunjukkan bahwa Optuna tidak hanya meningkatkan akurasi tetapi juga mengurangi kesalahan klasifikasi, yang tercermin dalam confusion matrix yang menunjukkan stabilitas dalam mengenali kedua kelas.

Secara keseluruhan, dampak optimasi hyperparameter terhadap hasil klasifikasi sentimen sangat signifikan. Model yang dituning dengan teknik seperti RandomizedSearchCV dan Optuna menunjukkan peningkatan akurasi dan stabilitas yang jelas dibandingkan dengan model dasar. Penggunaan teknik tuning ini terbukti efektif dalam meningkatkan performa model, yang sangat penting dalam aplikasi analisis sentimen yang memerlukan akurasi tinggi. Dengan demikian, penerapan metode optimasi yang tepat dapat secara substansial meningkatkan kemampuan klasifikasi model dalam menangani data yang kompleks dan beragam.


8.3. Diskusi Hasil

Analisis tentang bagaimana model dapat menangani variabilitas bahasa.

Dalam diskusi hasil mengenai analisis bagaimana model dapat menangani variabilitas bahasa, penelitian ini menunjukkan bahwa

pendekatan yang digunakan dalam model klasifikasi sentimen, baik TF-IDF maupun Word2Vec, memiliki kemampuan yang berbeda dalam menangkap nuansa dan kompleksitas bahasa. Variabilitas bahasa, yang mencakup penggunaan sinonim, frasa idiomatik, dan konteks yang bervariasi, menjadi tantangan utama dalam analisis sentimen, dan pendekatan yang tepat dapat meningkatkan akurasi klasifikasi.

Model Word2Vec, yang mengandalkan representasi vektor berbasis semantik, menunjukkan potensi yang kuat dalam menangkap konteks kata. Dalam evaluasi model Word2Vec + SVM tanpa tuning, akurasi tercatat 80.71% dengan nilai AUC 0.89 (Gambar 33). Meskipun model ini mampu mempertahankan informasi semantik antar kata, performanya masih terbilang rendah dibandingkan TF-IDF. Hal ini disebabkan oleh representasi rata-rata yang digunakan dalam pembentukan vektor kalimat, yang dapat menghilangkan informasi penting tentang hubungan antar kata dalam kalimat. Sebagai contoh, model ini mengalami kesulitan dalam membedakan sentimen positif dan negatif ketika konteks kalimat tidak jelas, seperti pada ulasan yang ambigu atau bercampur. Namun, ketika dilakukan tuning hyperparameter menggunakan RandomizedSearchCV, model Word2Vec menunjukkan peningkatan yang signifikan dengan akurasi mencapai 84.39% dan AUC sebesar 0.92



Gambar 39. ROC Curve - Word2Vec SVM RandomizedSearchCV

Tuning parameter seperti C dan gamma memungkinkan model untuk lebih responsif terhadap variasi dalam data, sehingga meningkatkan kemampuannya dalam menangkap nuansa bahasa yang lebih halus. Hasil ini menunjukkan bahwa optimasi parameter dapat membantu mengatasi kelemahan inherent dalam representasi Word2Vec, sehingga model menjadi lebih kompetitif dalam klasifikasi sentimen.

Di sisi lain, model TF-IDF + SVM menunjukkan performa yang lebih konsisten dalam menangani variabilitas bahasa. Dengan akurasi 84.38% dan AUC 0.93 (Gambar 21), model ini berhasil menangkap pola bahasa dengan baik, meskipun tidak selalu dapat menangani konteks yang kompleks seperti yang dilakukan oleh Word2Vec. TF-IDF berfungsi dengan menghitung frekuensi kata yang dibobot berdasarkan seberapa jarang kata tersebut muncul dalam seluruh korpus, sehingga memberikan bobot lebih pada kata-kata yang dianggap lebih informatif. Meskipun pendekatan ini efektif, ia mungkin tidak cukup untuk menangkap nuansa yang lebih halus dalam konteks kalimat. Penggunaan metode tuning seperti Optuna pada model TF-IDF + SVM menunjukkan hasil terbaik dengan akurasi 86.68% (Gambar 37). Ini membuktikan bahwa dengan pemilihan parameter yang tepat, model dapat lebih baik dalam mengadaptasi diri terhadap variasi bahasa yang ada. Selain itu, AUC yang tinggi menunjukkan bahwa model ini mampu membedakan antara sentimen positif dan negatif dengan baik, bahkan dalam konteks yang lebih rumit.

Secara keseluruhan, hasil penelitian ini menunjukkan bahwa kemampuan model dalam menangani variabilitas bahasa sangat bergantung pada metode representasi fitur yang digunakan dan optimasi yang diterapkan. Word2Vec, meskipun memiliki potensi dalam menangkap konteks semantik, memerlukan tuning yang cermat untuk mengatasi kelemahan dalam representasi vektor. Di sisi lain, TF-IDF menawarkan pendekatan yang lebih stabil tetapi mungkin kurang sensitif terhadap nuansa bahasa yang kompleks. Oleh karena itu, kombinasi antara kedua pendekatan ini, dengan penekanan pada tuning yang efektif, dapat menghasilkan model klasifikasi sentimen yang lebih baik dan lebih adaptif terhadap variabilitas bahasa.

Kelemahan dan kekuatan model dalam mengklasifikasikan sentimen pada ulasan produk.

Dalam diskusi hasil analisis tentang kelemahan dan kekuatan model dalam mengklasifikasikan sentimen pada ulasan produk, terdapat beberapa poin penting yang perlu diperhatikan. Penelitian ini menguji dua pendekatan utama: TF-IDF + SVM dan Word2Vec + SVM, serta mengoptimalkan model-model tersebut dengan berbagai teknik tuning hyperparameter, termasuk RandomizedSearchCV, GridSearchCV, dan Optuna. Hasil evaluasi menunjukkan bahwa kedua pendekatan memiliki kekuatan dan kelemahan masing-masing dalam mengatasi variabilitas bahasa dan kompleksitas sentimen dalam ulasan produk.

Kekuatan utama dari model TF-IDF + SVM terletak pada kemampuannya untuk menangkap pola linguistik yang jelas dalam data. Model ini tanpa tuning mencapai akurasi sebesar 84.38% dengan nilai AUC (Area Under Curve) 0.93, menunjukkan kemampuan klasifikasi yang sangat baik (Gambar 37). Keberhasilan ini disebabkan oleh fakta bahwa TF-IDF memberikan bobot lebih pada kata-kata yang jarang muncul, sehingga meningkatkan sensitivitas model terhadap kata-kata kunci yang memiliki makna penting dalam konteks sentimen. Selain itu, model ini menunjukkan keseimbangan yang baik antara precision dan recall, dengan nilai F1-score yang relatif tinggi untuk kedua kelas. Namun, kelemahan dari pendekatan ini adalah ketidakmampuannya untuk menangkap konteks semantik yang lebih dalam, yang sering kali diperlukan untuk analisis sentimen yang lebih kompleks.

Di sisi lain, model Word2Vec + SVM menunjukkan kekuatan dalam menangkap konteks semantik antar kata. Dengan menggunakan representasi vektor yang kaya makna, Word2Vec mampu mempertahankan hubungan antara kata-kata dalam kalimat, yang memberikan keuntungan dalam memahami nuansa sentimen. Namun, tanpa tuning, model ini hanya mencapai akurasi 80.71% dan nilai AUC 0.89, yang menunjukkan bahwa performanya masih di bawah TF-IDF. Kelemahan utama dari Word2Vec adalah bahwa representasi rata-rata yang digunakan dalam pembentukan vektor kalimat cenderung menghilangkan informasi penting, sehingga menyebabkan kesulitan dalam membedakan sentimen positif dan negatif secara akurat.

Setelah penerapan teknik tuning seperti RandomizedSearchCV dan Optuna, model Word2Vec menunjukkan peningkatan yang signifikan. Dengan RandomizedSearchCV, akurasi meningkat menjadi 84.39% dan AUC 0.92, sementara Optuna berhasil mencapai akurasi tertinggi sebesar 83.81% (. Hasil ini menunjukkan bahwa tuning hyperparameter sangat penting untuk meningkatkan kinerja model, meskipun masih belum melampaui performa TF-IDF. Penerapan RandomizedSearchCV dan Optuna memungkinkan eksplorasi parameter yang lebih efisien dan efektif, yang membantu model dalam mengatasi kelemahan inherent dari representasi Word2Vec.

Dalam konteks ini, penggunaan teknik tuning yang tepat menjadi krusial untuk memaksimalkan kekuatan model. TF-IDF + SVM dengan tuning menunjukkan performa yang stabil dan akurat, menjadikannya pilihan yang lebih baik untuk aplikasi analisis sentimen yang memerlukan akurasi tinggi. Sementara itu, Word2Vec + SVM, meskipun memiliki potensi dalam menangkap konteks semantik, memerlukan optimasi yang lebih mendalam untuk mencapai hasil yang kompetitif.

BAB 9

Implikasi Praktis dalam E-Commerce

9.1. Penggunaan Analisis Sentimen untuk Pengambilan Keputusan

Perusahaan e-commerce dapat menggunakan analisis sentimen untuk meningkatkan layanan pelanggan dan reputasi merek dengan cara yang strategis. Analisis sentimen memungkinkan perusahaan untuk memahami persepsi konsumen terhadap produk dan layanan mereka melalui ulasan yang diberikan. Dalam penelitian ini, model Support Vector Machine (SVM) telah diterapkan pada 2.902 ulasan produk berbahasa Indonesia, menunjukkan bahwa optimasi hyperparameter dapat meningkatkan akurasi klasifikasi sentimen dari 79,5% menjadi 87% dengan menggunakan teknik ekstraksi fitur seperti TF-IDF dan Word2Vec.

Dengan menerapkan analisis sentimen, perusahaan dapat mengidentifikasi masalah yang berulang dalam produk atau layanan dengan cepat. Misalnya, jika banyak ulasan negatif menyebutkan masalah yang sama, perusahaan dapat segera melakukan perbaikan. Selain itu, analisis sentimen memberikan wawasan yang berharga untuk strategi pemasaran. Dengan memahami sentimen positif dan negatif, perusahaan dapat menyesuaikan kampanye pemasaran mereka untuk menarik perhatian konsumen yang lebih luas.

Data yang digunakan dalam penelitian ini menunjukkan bahwa teknik ekstraksi fitur seperti Word2Vec memberikan akurasi yang lebih tinggi dibandingkan TF-IDF, karena Word2Vec mampu menangkap hubungan semantik antar kata, yang penting dalam konteks analisis sentimen. Oleh karena itu, perusahaan e-commerce disarankan untuk menggunakan analisis sentimen secara rutin untuk memantau ulasan

pelanggan dan menyesuaikan strategi mereka berdasarkan wawasan yang diperoleh. Dengan demikian, analisis sentimen tidak hanya meningkatkan layanan pelanggan tetapi juga memperkuat reputasi merek di pasar yang kompetitif.

Analisis sentimen dapat menjadi alat bantu yang sangat berharga dalam perencanaan produk dan pemasaran, terutama di sektor e-commerce. Dengan menggunakan teknik analisis sentimen, perusahaan dapat mengevaluasi umpan balik pelanggan yang terkandung dalam ulasan produk. Dalam penelitian ini, model klasifikasi sentimen menggunakan Support Vector Machine (SVM) telah diterapkan pada 2.902 ulasan produk berbahasa Indonesia. Proses ini melibatkan pengumpulan data, preprocessing, dan penerapan teknik ekstraksi fitur seperti TF-IDF dan Word2Vec. Hasil menunjukkan bahwa optimasi hyperparameter menggunakan metode seperti GridSearchCV dan Optuna dapat meningkatkan akurasi model dari 79,5% menjadi 87%.

Dengan menganalisis sentimen, perusahaan dapat mengidentifikasi masalah yang mungkin ada pada produk atau layanan mereka dengan cepat. Misalnya, jika banyak ulasan negatif terkait kualitas produk tertentu, perusahaan dapat segera mengambil tindakan perbaikan. Selain itu, analisis sentimen memberikan wawasan yang berharga untuk merancang strategi pemasaran yang lebih efektif. Dengan memahami sentimen positif dan negatif, perusahaan dapat menyesuaikan kampanye pemasaran mereka untuk menarik perhatian konsumen yang lebih luas.

Data yang digunakan dalam penelitian ini mencakup berbagai kategori produk, sehingga memberikan representasi yang lebih baik dari variasi sentimen. Proses preprocessing yang dilakukan, termasuk tokenisasi, penghapusan stopwords, dan stemming, meningkatkan kualitas data yang digunakan untuk pelatihan model. Dengan demikian, analisis sentimen tidak hanya membantu perusahaan memahami kepuasan pelanggan, tetapi juga meningkatkan efisiensi dalam pengambilan keputusan berbasis data.

9.2. Penerapan Model Sentimen dalam Sistem E-Commerce

Penerapan Model sentimen dalam sistem e-commerce merupakan langkah strategis yang memungkinkan perusahaan untuk meningkatkan pengalaman pelanggan dan mengelola reputasi merek secara lebih efektif. Dalam penelitian ini, model klasifikasi sentimen menggunakan algoritma Support Vector Machine (SVM) diintegrasikan ke dalam sistem ulasan produk e-commerce berbahasa Indonesia. Model ini dirancang untuk mengklasifikasikan sentimen ulasan menjadi dua kategori: positif dan negatif, berdasarkan 2.902 ulasan produk yang telah dilabeli. Proses ini mencakup beberapa tahapan penting, termasuk pengumpulan data, preprocessing, dan pengembangan model, yang semuanya dijelaskan secara rinci dalam dokumen.

Data yang digunakan dalam penelitian ini menunjukkan keberagaman kategori produk, yang sangat penting untuk meningkatkan akurasi model. Penggunaan teknik ekstraksi fitur seperti TF-IDF dan Word2Vec memungkinkan model SVM untuk memahami konteks dan hubungan semantik antar kata, yang sangat krusial dalam analisis sentimen. Setelah menerapkan optimasi hyperparameter menggunakan metode seperti GridSearchCV dan Optuna, model SVM menunjukkan akurasi sebesar 87%, yang mengindikasikan peningkatan signifikan dibandingkan dengan model dasar.

Melalui integrasi Model sentimen ini, platform e-commerce dapat memetakan kepuasan dan keluhan pelanggan secara real-time, yang memungkinkan identifikasi isu kualitas yang lebih cepat dan penyesuaian strategi pemasaran yang lebih tepat. Dengan demikian, penerapan Model sentimen tidak hanya meningkatkan layanan pelanggan tetapi juga memberikan wawasan berharga bagi pengambilan keputusan berbasis data dalam konteks e-commerce.

Implementasi model hybrid dalam aplikasi nyata untuk mendeteksi sentimen pelanggan dapat dilakukan dengan menggabungkan beberapa teknik analisis sentimen yang terbukti efektif. Dalam penelitian ini, model hybrid yang mengintegrasikan Support Vector Machine (SVM), Convolutional Neural Networks (CNN), dan Bidirectional Long Short-Term Memory (BiLSTM) digunakan untuk meningkatkan akurasi klasifikasi sentimen pada ulasan produk e-commerce berbahasa Indonesia.

Model SVM dipilih karena kemampuannya dalam menangani data berdimensi tinggi dan kompleks, yang sering ditemukan dalam analisis teks. Pada tahun pertama penelitian, model ini dioptimalkan menggunakan teknik seperti GridSearchCV dan RandomizedSearchCV untuk meningkatkan akurasi dari 79,5% menjadi 87% dengan menggunakan teknik ekstraksi fitur TF-IDF dan Word2Vec. Sementara TF-IDF berfokus pada frekuensi kata, Word2Vec menangkap hubungan semantik antar kata, sehingga memberikan pemahaman yang lebih baik tentang konteks ulasan.

Pada tahun kedua, model hybrid yang menggabungkan CNN dan BiLSTM dengan SVM dikembangkan. CNN berfungsi untuk mengekstrak fitur lokal dari teks, sedangkan BiLSTM menangkap ketergantungan jangka panjang dalam kalimat. Dengan pendekatan ini, model hybrid mampu memahami konteks yang lebih kompleks dalam ulasan produk, meningkatkan akurasi klasifikasi sentimen secara signifikan.

9.3. Manfaat Model Hybrid untuk Perusahaan E-Commerce

Penggunaan model hybrid dalam analisis sentimen menawarkan sejumlah keuntungan dibandingkan dengan model tradisional seperti Support Vector Machine (SVM) yang berdiri sendiri. Salah satu keuntungan utama adalah kemampuan model hybrid untuk menangkap nuansa kompleks dalam data teks, yang sering kali tidak dapat diidentifikasi oleh model tradisional. Dalam penelitian ini, model hybrid yang menggabungkan Convolutional Neural Networks (CNN) dan Bidirectional Long Short-Term Memory (BiLSTM) dengan SVM menunjukkan peningkatan akurasi yang signifikan dalam klasifikasi sentimen ulasan produk e-commerce.

Model hybrid ini menggabungkan kekuatan dari CNN dalam mengekstraksi fitur lokal dan BiLSTM dalam menangkap ketergantungan jangka panjang antar kata. CNN efektif dalam mendeteksi pola-pola penting dalam teks, sementara BiLSTM mampu memahami konteks yang lebih luas, yang sangat penting dalam analisis sentimen. Dengan pendekatan ini, model dapat menangani kalimat yang lebih kompleks, di

mana sentimen sering kali dipengaruhi oleh frasa lokal dan konteks yang lebih luas.

Selain itu, model hybrid juga menunjukkan ketahanan yang lebih baik terhadap noise dan ambiguitas dalam data. Dengan memanfaatkan ekstraksi fitur dari CNN dan pemrosesan sekuensial dari BiLSTM, model ini dapat mengurangi kesalahan klasifikasi yang sering terjadi pada model tradisional, terutama dalam menangani teks yang mengandung ironi atau nuansa halus. Penelitian ini menunjukkan bahwa model hybrid dapat meningkatkan akurasi klasifikasi sentimen hingga 10% dibandingkan dengan model SVM tradisional, menjadikannya pilihan yang lebih efektif dalam konteks analisis sentimen di e-commerce.

Peningkatan akurasi dan efisiensi dalam memproses ulasan produk di e-commerce dapat dicapai melalui penerapan teknik analisis sentimen yang canggih. Dalam penelitian ini, model klasifikasi sentimen menggunakan Support Vector Machine (SVM) dioptimalkan dengan metode ekstraksi fitur seperti TF-IDF dan Word2Vec. Dengan memanfaatkan 2.902 ulasan produk berbahasa Indonesia, penelitian ini menunjukkan bahwa optimasi hyperparameter menggunakan GridSearchCV, RandomizedSearchCV, dan Optuna dapat secara signifikan meningkatkan akurasi model. Hasilnya, model yang dioptimalkan dengan Optuna mencapai akurasi 87%, meningkat dari 79,5% pada model dasar.

Efisiensi dalam analisis sentimen juga diperoleh melalui teknik preprocessing yang efektif, termasuk tokenisasi, penghapusan stopwords, dan stemming. Proses ini membantu mengurangi noise dalam data dan meningkatkan kualitas fitur yang digunakan dalam model. Penggunaan TF-IDF memberikan bobot lebih tinggi pada kata-kata yang relevan, sementara Word2Vec menangkap hubungan semantik antar kata, yang sangat penting dalam konteks analisis sentimen yang kompleks.

Dengan memanfaatkan model yang telah dioptimalkan, perusahaan e-commerce dapat secara otomatis menganalisis ulasan produk dalam waktu nyata, memungkinkan mereka untuk merespons umpan balik pelanggan dengan lebih cepat dan meningkatkan retensi pelanggan. Penelitian ini menunjukkan bahwa kombinasi dari teknik analisis sentimen

yang tepat dan optimasi hyperparameter dapat memberikan kontribusi yang signifikan terhadap pengambilan keputusan berbasis data di sektor e-commerce.

.

BAB 10

Kesimpulan dan Rekomendasi

10.1. Kesimpulan

Penelitian ini menunjukkan bahwa peningkatan akurasi analisis sentimen dapat dicapai dengan penerapan teknik ekstraksi fitur yang efektif dan optimasi hyperparameter. Menggunakan Support Vector Machine (SVM) untuk mengolah 2.902 ulasan produk e-commerce berbahasa Indonesia, penelitian ini membandingkan teknik ekstraksi fitur TF-IDF dan Word2Vec. Hasil menunjukkan bahwa Word2Vec memberikan akurasi lebih tinggi, mencapai 87%, dibandingkan 83,5% untuk TF-IDF. Optimasi hyperparameter melalui GridSearchCV, RandomizedSearchCV, dan Optuna menunjukkan bahwa Optuna memberikan akurasi tertinggi, yaitu 87%, yang secara signifikan meningkatkan performa model. Model hybrid yang menggabungkan Convolutional Neural Networks (CNN) dan Bidirectional Long Short-Term Memory (BiLSTM) dengan SVM juga memberikan akurasi lebih baik, mengurangi ketergantungan pada teknik rekayasa fitur manual, dan meningkatkan akurasi klasifikasi sentimen hingga 5-10% lebih tinggi dibandingkan SVM tunggal. Penggunaan Optuna lebih lanjut mempercepat pencarian parameter optimal, menjadikan model lebih efisien untuk analisis sentimen secara real-time

10.2. Rekomendasi untuk Penelitian Selanjutnya

Pengembangan lebih lanjut dalam analisis sentimen dapat dilakukan dengan mengintegrasikan arsitektur deep learning seperti Convolutional Neural Networks (CNN) dan Bidirectional Long Short-Term Memory (BiLSTM). CNN efektif untuk mengekstraksi fitur lokal dari teks, sementara BiLSTM dapat memahami ketergantungan antar kata dalam kalimat yang lebih panjang, sehingga menangkap konteks jangka panjang. Dalam penelitian ini, model hybrid yang menggabungkan CNN, BiLSTM, dan Support Vector Machine (SVM) diusulkan untuk meningkatkan akurasi klasifikasi sentimen ulasan produk e-commerce. Model ini diharapkan dapat menangani nuansa sentimen yang kompleks

seperti ironi dan ambiguitas, memberikan hasil lebih akurat dibandingkan model tradisional. Penggunaan teknik optimasi hyperparameter seperti Optuna juga diterapkan untuk meningkatkan efisiensi pencarian parameter optimal, mempercepat proses pelatihan, dan meningkatkan kinerja model. Dengan demikian, integrasi teknik deep learning dan optimasi hyperparameter dapat menghasilkan Model sentimen yang lebih canggih, efisien, dan efektif dalam menangani kompleksitas bahasa dalam ulasan produk e-commerce

10.3. Implikasi Praktis

Perusahaan e-commerce dapat memanfaatkan analisis sentimen untuk meningkatkan pengalaman pelanggan dan pengambilan keputusan berbasis data. Menggunakan model klasifikasi sentimen seperti Support Vector Machine (SVM) yang dioptimalkan, perusahaan dapat menganalisis ulasan produk secara otomatis untuk mengidentifikasi sentimen positif, negatif, atau netral. Dengan menerapkan teknik ekstraksi fitur seperti TF-IDF dan Word2Vec, perusahaan dapat menangkap nuansa dan konteks dalam ulasan. TF-IDF memberikan bobot tinggi pada kata-kata yang jarang tetapi signifikan, sementara Word2Vec menangkap hubungan semantik antar kata. Hasil analisis ini membantu perusahaan memetakan kepuasan pelanggan, mengidentifikasi masalah kualitas produk, dan memonitor reputasi merek secara real-time. Keputusan berbasis data yang dihasilkan memungkinkan respons yang cepat dan tepat terhadap umpan balik pelanggan serta adaptasi strategi pemasaran dan pengembangan produk sesuai kebutuhan konsumen. Penerapan analisis sentimen memberikan keunggulan kompetitif yang penting dalam industri e-commerce yang dinamis

DAFTAR PUSTAKA

- Abdullah, D., & Abdulazeez, A. (2021). Machine learning applications based on SVM classification: A review. *Qubahan Academic Journal*, 1(2), 81-90. <https://doi.org/10.48161/qaj.v1n2a50>
- Alshari, E., Azman, A., Doraisamy, S., Mustapha, N., & Alksher, M. (2020). Senti2vec: An effective feature extraction technique for sentiment analysis based on Word2Vec. *Malaysian Journal of Computer Science*, 33(3), 240-251. <https://doi.org/10.22452/mjcs.vol33no3.5>
- Alzami, F., Udayanti, E., Prabowo, D., & Megantara, R. (2020). Document preprocessing with tf-idf to improve the polarity classification performance of unstructured sentiment analysis. *Kinetik Game Technology Information System Computer Network Computing Electronics and Control*, 5(3), 235-242. <https://doi.org/10.22219/kinetik.v5i3.1066>
- Ardhani, B., Chamidah, N., & Saifudin, T. (2021). Sentiment analysis towards kartu prakerja using text mining with support vector machine and radial basis function kernel. *Journal of Information Systems Engineering and Business Intelligence*, 7(2), 119-128. <https://doi.org/10.20473/jisebi.7.2.119-128>
- Bergstra, J., Bardenet, R., Cox, D., & Keirse, R. (2011). Making a science of model search: Hyperparameter optimization in hundreds of dimensions for vision architectures. In *Proceedings of the 28th International Conference on Machine Learning (ICML-11)* (pp. 115-122).
- Bordoloi, M., & Biswas, S. (2023). Sentiment analysis: A survey on design framework, applications and future scopes. *Artificial Intelligence Review*, 56(11), 12505-12560. <https://doi.org/10.1007/s10462-023-10442-2>
- Chen, N., Sun, Y., & Yan, Y. (2023). Sentiment analysis and research based on two-channel parallel hybrid neural network model with attention mechanism. *IET Control Theory and Applications*, 17(17), 2259–2267. <https://doi.org/10.1049/cth2.12463>

- Dong, M., Li, Y., Tang, X., Xu, J., Bi, S., & Cai, Y. (2020). Variable convolution and pooling convolutional neural network for text sentiment classification. *IEEE Access*, 8, 16174-16186. <https://doi.org/10.1109/access.2020.2966726>
- Elgeldawi, E., Sayed, A., Galal, A., & Zaki, A. (2021). Hyperparameter tuning for machine learning algorithms used for Arabic sentiment analysis. *Informatics*, 8(4), 79. <https://doi.org/10.3390/informatics8040079>
- Gandhi, R., Merikapudi, S., & Narayana, M. (2023). Text classification using incremental learning for many classes of support vector machines. *IJSMIEN*, 01(02), 44-51. <https://doi.org/10.58599/ijsmien.2023.1205>
- Han, K., Chien, W., Chiu, C., & Cheng, Y. (2020). Application of support vector machine (SVM) in the sentiment analysis of twitter dataset. *Applied Sciences*, 10(3), 1125. <https://doi.org/10.3390/app10031125>
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction*. Springer Science & Business Media.
- Hoiriyah, H., Qomariya, N., Darmawan, A., Walid, M., & Efenie, Y. (2023). Sentiment analysis on LGBT issues in Indonesia with lexicon-based and support vector machine algorithms. *Jurnal Pilar Nusa Mandiri*, 19(1), 27-36. <https://doi.org/10.33480/pilar.v19i1.4183>
- Jadia, H. (2023). Comparative analysis of sentiment analysis techniques: SVM, logistic regression, and TF-IDF feature extraction. *International Research Journal of Modernization in Engineering Technology and Science*. <https://doi.org/10.56726/irjmets45265>
- Jollyta, D., Gusrianty, G., Prihandoko, P., & Sukrianto, D. (2023). N-gram and kernel performance using support vector machine algorithm for fake news detection system. *Ilkom Jurnal Ilmiah*, 15(3), 398-404. <https://doi.org/10.33096/ilkom.v15i3.1770.398-404>
- Mikolov, T., Chen, K., Corrado, G., & Dean, J. (2013). Efficient estimation of word representations in vector space. *arXiv:1301.3781*.

- Mirdan, A., Buyruköğlu, S., & Baker, M. (2025). Advanced deep learning techniques for sentiment analysis: Combining Bi-LSTM, CNN, and attention layers. *International Journal of Advances in Intelligent Informatics*, 11(1), 55–68. <https://doi.org/10.26555/ijain.v11i1.1848>
- Nafis, N., & Awang, S. (2021). An enhanced hybrid feature selection technique using term frequency-inverse document frequency and support vector machine-recursive feature elimination for sentiment classification. *IEEE Access*, 9, 52177-52192. <https://doi.org/10.1109/access.2021.3069001>
- Nguyen, H. (2021). Residual attention bi-directional long short-term memory for Vietnamese sentiment classification. *Journal of Science and Technique*, 9(2), 45–59. <https://doi.org/10.56651/lqdtu.jst.v9.n02.212.ict>
- Noor, M., Gata, W., Risnandar, R., Fakhruddin, F., & Novitarani, A. (2022). Optimization of sentiment analysis of program sembako (BPNT) based on twitter. *Journal of Applied Engineering and Technological Science (Jaets)*, 4(1), 223-234. <https://doi.org/10.37385/jaets.v4i1.1006>
- Nugraha, A. (2022). Naïve Bayes dan support vector machine berbasis PSO untuk seleksi fitur pada sentiment analysis. *Innovation in Research of Informatics (Innovatics)*, 4(2). <https://doi.org/10.37058/innovatics.v4i2.5291>
- Pambudi, A., & Suprpto, S. (2021). Effect of sentence length in sentiment analysis using support vector machine and convolutional neural network method. *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, 15(1), 21. <https://doi.org/10.22146/ijccs.61627>
- Ramasamy, L., Kadry, S., & Lim, S. (2021). Selection of optimal hyper-parameter values of support vector machine for sentiment analysis tasks using nature-inspired optimization methods. *Bulletin of Electrical Engineering and Informatics*, 10(1), 290-298. <https://doi.org/10.11591/eei.v10i1.2098>
- Rezapour, M. (2020). Sentiment classification of skewed shoppers' reviews using machine learning techniques, examining the textual

features. *Engineering Reports*,

3(1). <https://doi.org/10.1002/eng2.12280>

Salsabila, S., Tyas, S., Romadhona, Y., & Purwitasari, D. (2023). Aspect-based sentiment and correlation-based emotion detection on tweets for understanding public opinion of covid-19. *Journal of Information Systems Engineering and Business Intelligence*, 9(1), 84-

94. <https://doi.org/10.20473/jisebi.9.1.84-94>

Setyawan, H., Azizah, L., & Pradani, A. (2023). Sentiment analysis of public responses on Indonesia government using Naïve Bayes and support vector machine. *Emerging Information Science and Technology*,

4(1), 1-7. <https://doi.org/10.18196/eist.v4i1.18681>

Su, S. (2022). Sentimental analysis applied on movie reviews. *Journal of Education Humanities and Social Sciences*, 3, 188-

195. <https://doi.org/10.54097/ehss.v3i.1685>

Wang, H. (2024). Word2vec and SVM fusion for advanced sentiment analysis on Amazon reviews. *Highlights in Science, Engineering and Technology*, 85, 743–749. <https://doi.org/10.54097/sw4pft19>

Biodata Penulis



Fauziah Hanum, S.Pd., M.Pd., adalah seorang akademisi yang menginspirasi, lahir di Kota Rantau Prapat, Kabupaten Labuhanbatu, Sumatera Utara, pada tahun 1978. Sebagai anak kelima dari sepuluh bersaudara, ia tumbuh dengan semangat belajar yang tinggi dan tekad untuk berkontribusi di dunia pendidikan. Setelah menyelesaikan pendidikan Strata 1 di Universitas Negeri Medan, ia melanjutkan studi dan meraih gelar Magister di Universitas Muslim Nusantara Medan, dengan fokus pada ilmu pendidikan. Saat ini, Fauziah mengabdikan diri sebagai dosen tetap di Universitas Labuhanbatu, menginspirasi mahasiswa dengan pengajaran yang mendalam dan membagikan pengetahuan melalui artikel ilmiah yang berkontribusi pada perkembangan ilmu pengetahuan. Dedikasinya terhadap pendidikan dan pengalamannya yang luas menjadikan Fauziah sosok yang berkomitmen dalam mencetak generasi yang berwawasan luas dan berkualitas.



Richi Andrianto, S.Kom., M.Kom Lahir di Bangun Jaya (Rokan Hulu-Riau), Tanggal 30 Maret 1993. Merupakan anak pertama dari tiga bersaudara, putra dari pasangan Wasidi dan Lina Yuliana. Pendidikan jenjang Strata Satu (S1) ditempuh di Universitas Pasir Pengaraian dengan Prodi Teknik Informatika. Kemudian melanjutkan pendidikan ke jenjang Strata Dua (S2) pada Program Magister Teknologi Informasi di Universitas Putra Indonesia "YPTK" Padang. Dan saat ini, tengah menempuh pendidikan pada Program Doktorat (S3) Teknologi Informasi dengan bidang keilmuan Data Science berfokus pada bidang Kecerdasan Buatan. Penulis aktif sebagai dosen tetap program studi Sistem Informasi Institut Teknologi dan Sains Padang Lawas Utara (ITS Paluta). Selain itu penulis juga aktif dalam berbagai kegiatan penelitian, pengembangan dan penerapan teknologi informasi khususnya pada bidang keilmuan kecerdasan buatan (artificial intelligence) dan penulisan buku. Secara berturut-turut dari tahun 2023 hingga 2025 lulus

hibah penelitian Kemdiktisaintek sebagai ketua peneliti. Penerbitan buku ini merupakan wujud kontribusi dalam pengembangan literasi teknologi dan penyebarluasan ilmu pengetahuan yang aplikatif dan relevan dengan kebutuhan masyarakat serta perkembangan zaman.



Anita Sri Rejeki Hutagaol, S.Pd., M.Pd., lahir di Kampung Jawa Pasar, Kabupaten Labuhan Batu, Sumatera Utara pada tahun 1988, merupakan anak keenam dari enam bersaudara. Ia menyelesaikan studi Sarjana di Universitas Negeri Medan pada jurusan Pendidikan Matematika, kemudian melanjutkan Pendidikan Pasca Sarjana dan meraih gelar Magister pada tahun 2015. Sejak 2016 hingga 2022, ia mengabdikan sebagai dosen di STKIP Persada Khatulistiwa Sintang, Kalimantan Barat. Pada tahun 2023, Anita bergabung dengan Universitas Labuhan Batu, Sumatera Utara, sebagai Dosen Tetap di Fakultas Ekonomi dan Bisnis. Selain mengajar, ia aktif dalam Tridarma Perguruan Tinggi, serta menulis berbagai artikel penelitian dan karya pengabdian kepada masyarakat.



Ibnu Rasyid Munthe, ST., M.Kom., lahir di Rantau Prapat, Kabupaten Labuhanbatu, pada 1987. Beliau menyelesaikan pendidikan S1 di Universitas Nurtanio Bandung dan S2 di Universitas Putra Indonesia (YPTK) Padang. Aktif menulis artikel ilmiah dan buku, Ibnu Rasyid Munthe saat ini mengajar di Universitas Labuhanbatu. Selain itu, beliau mengelola kanal YouTube @manjaddawajada2022 sebagai media pembelajaran dan berbagi pengetahuan, memberikan kontribusi dalam dunia pendidikan dan teknolog

Ringkasan Buku

Buku monograf ini berjudul "Membangun Model Sentimen Dengan Mengintegrasikan Linguistik dan Teknologi untuk E-Commerce". Buku ini menawarkan panduan praktis bagi peneliti dan praktisi di bidang e-commerce untuk mengembangkan sistem analisis sentimen yang efektif. Dalam konteks e-commerce, analisis sentimen sangat penting untuk memahami persepsi konsumen terhadap produk berdasarkan ulasan yang mereka berikan.

Buku ini membahas teknik ekstraksi fitur seperti TF-IDF dan Word2Vec, serta penerapan model pembelajaran mesin seperti Support Vector Machine (SVM) untuk mengklasifikasikan sentimen. Pembaca akan diperkenalkan pada tantangan yang dihadapi dalam analisis sentimen, termasuk ambiguitas bahasa, ironi, dan penggunaan slang dalam ulasan. Melalui pendekatan yang menggabungkan teori linguistik dan teknik machine learning, buku ini menunjukkan cara untuk meningkatkan akurasi analisis sentimen hingga 87%.

Dengan penjelasan yang jelas dan contoh yang relevan, buku ini bertujuan untuk membantu perusahaan e-commerce dalam merespons umpan balik pelanggan secara lebih cepat dan tepat, serta merancang strategi pemasaran yang lebih efisien. Diharapkan, buku ini dapat menjadi referensi penting bagi siapa saja yang ingin memahami dan menerapkan analisis sentimen dalam konteks e-commerce.



ISBN 978-634-04-2310-5 (PDF)



9

786340

423105