



BUKU AJAR DETEKSI SENTIMEN DALAM E-COMMERCE KONSEP, ALAT UKUR DAN APLIKASINYA



Shabrina Rasyid Munthe, S.Pd.I., M.S, Samsir, S.T., M.Kom,
Rina Asriani Levianti, S.E., M.Ak, Muhammad Rusli, M.S,
Rizki Lestari, M.Pd, Yuannisah Aini Nasution, S.Pd., M.Pd,
Midrawati Hasibuan, S.Pd., M.M, Wita Ferwati, M.Pd,
Ibnu Rasyid Munthe, S.T., M.Kom

BUKU AJAR
DETEKSI SENTIMEN DALAM E-COMMERCE
KONSEP, ALAT UKUR DAN APLIKASINYA

UU No 28 tahun 2014 tentang Hak Cipta

Fungsi dan sifat hak cipta Pasal 4

Hak Cipta sebagaimana dimaksud dalam Pasal 3 huruf a merupakan hak eksklusif yang terdiri atas hak moral dan hak ekonomi.

Pembatasan Pelindungan Pasal 26

Ketentuan sebagaimana dimaksud dalam Pasal 23, Pasal 24, dan Pasal 25 tidak berlaku terhadap:

penggunaan kutipan singkat Ciptaan dan/atau produk Hak Terkait untuk pelaporan peristiwa aktual yang ditujukan hanya untuk keperluan penyediaan informasi aktual;

Penggandaan Ciptaan dan/atau produk Hak Terkait hanya untuk kepentingan penelitian ilmu pengetahuan;

Penggandaan Ciptaan dan/atau produk Hak Terkait hanya untuk keperluan pengajaran, kecuali pertunjukan dan Fonogram yang telah dilakukan Pengumuman sebagai bahan ajar; dan

penggunaan untuk kepentingan pendidikan dan pengembangan ilmu pengetahuan yang memungkinkan suatu Ciptaan dan/atau produk Hak Terkait dapat digunakan tanpa izin Pelaku Pertunjukan, Produser Fonogram, atau Lembaga Penyiaran.

Sanksi Pelanggaran Pasal 113

Setiap Orang yang dengan tanpa hak melakukan pelanggaran hak ekonomi sebagaimana dimaksud dalam Pasal 9 ayat (1) huruf i untuk Penggunaan Secara Komersial dipidana dengan pidana penjara paling lama 1 (satu) tahun dan/atau pidana denda paling banyak Rp100.000.000 (seratus juta rupiah).

Setiap Orang yang dengan tanpa hak dan/atau tanpa izin Pencipta atau pemegang Hak Cipta melakukan pelanggaran hak ekonomi Pencipta sebagaimana dimaksud dalam Pasal 9 ayat (1) huruf c, huruf d, huruf f, dan/atau huruf h untuk Penggunaan Secara Komersial dipidana dengan pidana penjara paling lama 3 (tiga) tahun dan/atau pidana denda paling banyak Rp500.000.000,00 (lima ratus juta rupiah).

Buku Ajar
Deteksi Sentimen dalam E-Commerce
Konsep, Alat Ukur dan Aplikasinya

Shabrina Rasyid Munthe, S.Pd.I., M.S
Samsir, S.T., M.Kom
Rina Asriani Levianti, S.E., M.Ak
Muhammad Rusli, M.S
Rizki Lestari, M.Pd
Yuannisah Aini Nasution, S.Pd., M.Pd
Midrawati Hasibuan, S.Pd., M.M
Wita Ferwati, M.Pd
Ibnu Rasyid Munthe, S.T., M.Kom



**BUKU AJAR DETEKSI SENTIMEN DALAM E-COMMERCE
KONSEP, ALAT UKUR DAN APLIKASINYA**

**Shabrina Rasyid Munthe, S.Pd.I., M.S, Samsir, S.T., M.Kom,
Rina Asriani Levianti, S.E., M.Ak, Muhammad Rusli, M.S,
Rizki Lestari, M.Pd, Yuannisah Aini Nasution, S.Pd., M.Pd,
Midrawati Hasibuan, S.Pd., M.M, Wita Ferwati, M.Pd,
Ibnu Rasyid Munthe, S.T., M.Kom**

Editor :
Sahat Parulian Sitorus

Desain Cover :
Nurhasanah

Sumber :
<https://isbn.jndi.my.id/products/buku-ajar-deteksi-sentimen-dalam-e-commerce-konsep-alat-ukur-dan-aplikasinya>

Tata Letak :
Ida Royani Sitorus

Ukuran :
Jml hal judul 217, Jml hal isi naskah 206, Uk: 14x21 cm

ISBN :
978-634-04-2225-2

Cetakan Pertama :
31 Juli 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

Perkembangan teknologi digital yang pesat telah mengubah cara konsumen berinteraksi dengan platform e-commerce, salah satunya melalui ulasan produk. Ulasan ini mengandung informasi penting, termasuk sentimen konsumen terhadap produk atau layanan yang ditawarkan. Oleh karena itu, pemahaman yang mendalam tentang sentimen dalam ulasan sangat penting untuk meningkatkan kualitas layanan dan produk.

Bahan ajar ini berjudul "***Deteksi Sentimen dalam E-Commerce Konsep, Alat Ukur, dan Aplikasinya***" yang bertujuan memberikan wawasan mengenai penerapan teknik Pemrosesan Bahasa Alami (NLP) dalam analisis sentimen e-commerce. NLP memungkinkan analisis dan klasifikasi sentimen dalam ulasan teks, apakah positif, negatif, atau netral.

Pembaca akan mempelajari teknik dasar NLP seperti tokenisasi, penghapusan stopword, stemming, serta ekstraksi fitur seperti TF-IDF dan Word2Vec. Teknik-teknik ini berguna untuk mengolah data teks besar menjadi informasi yang bermanfaat bagi perusahaan. Semoga bahan ajar ini memperluas wawasan dalam mengaplikasikan NLP di e-commerce.

Rantauprapat, Juli 2025

Tim Penulis

KATA PENGANTAR

Puji syukur kami panjatkan kepada Tuhan Yang Maha Esa atas rahmat dan karunia-Nya, sehingga bahan ajar ini dapat diselesaikan dengan baik. Bahan ajar ini berjudul "***Deteksi Sentimen dalam E-Commerce Konsep, Alat Ukur, dan Aplikasinya***", yang bertujuan memberikan pemahaman tentang penerapan teknik Pemrosesan Bahasa Alami (NLP) dalam analisis sentimen, khususnya dalam e-commerce.

E-commerce telah menjadi sektor utama dalam perdagangan digital, dan ulasan produk dari konsumen memiliki peran penting dalam pengambilan keputusan pembelian. Oleh karena itu, analisis sentimen terhadap ulasan produk sangat penting untuk memahami pandangan konsumen, baik itu positif, negatif, atau netral. Sentimen ini memberikan wawasan berharga bagi perusahaan dalam pengembangan produk dan strategi bisnis.

Bahan ajar ini mengulas teknik-teknik dasar NLP seperti tokenisasi, penghapusan stopword, stemming, serta ekstraksi fitur seperti TF-IDF dan Word2Vec. Dengan pemahaman ini, diharapkan pembaca dapat mengembangkan sistem analisis sentimen yang efektif untuk meningkatkan kepuasan pelanggan dalam e-commerce.

Rantauprapat, Juli 2025

Tim Penulis

DAFTAR ISI

PRAKATA	vi
KATA PENGANTAR	vii
DAFTAR ISI	viii
Buku Ajar Berbasis OBE	1
A. Profil Lulusan	1
B. Capaian Pembelajaran Lulusan (CPL)	1
C. Capaian Pembelajaran Mata Kuliah (CPMK)	1
D. Metode Pembelajaran	3
E. Metode Asesmen	4
F. Alokasi Pertemuan (16 Pertemuan)	5
G. Kriteria Penilaian	6
Pengantar Analisis Sentimen	7
1. Konsep Dasar	7
2. Aplikasi	11
3. Studi Kasus	13
4. Soal Latihan	14
Pemrosesan Bahasa Alami (NLP) untuk Bahasa Indonesia	18
1. Konsep Dasar	18
2. Aplikasi	27
3. Studi Kasus	29
4. Soal Latihan	32
Ekstraksi Fitur Tradisional (TF-IDF)	35
1. Konsep Dasar	35
2. Aplikasi	43
3. Studi Kasus	46
4. Soal Latihan	47
Ekstraksi Fitur N-Gram	48
1. Konsep Dasar	48
2. Aplikasi	51
3. Studi Kasus	51
4. Soal Latihan	53
Word Embedding (Word2Vec)	56

1. Konsep Dasar	56
2. Aplikasi	68
3. Studi Kasus	71
4. Soal Latihan	73
Integrasi Fitur Multimodal	75
1. Konsep Dasar	75
2. Aplikasi	82
3. Studi Kasus	89
4. Soal Latihan	91
Konsep Ketidakseimbangan Kelas	93
1. Konsep Dasar	93
2. Aplikasi	104
3. Studi Kasus	105
4. Soal Latihan	107
Ujian Tengah Semester	110
Teknik Resampling (SMOTE)	115
1. Konsep Dasar	115
2. Aplikasi	119
3. Studi Kasus	121
4. Soal Latihan	123
Teknik Hybrid Resampling (SMOTEENN)	125
1. Konsep Dasar	125
2. Aplikasi	130
3. Studi Kasus	132
4. Soal Latihan	133
Model Naive Bayes	136
1. Konsep Dasar	136
2. Aplikasi	141
3. Studi Kasus	142
4. Soal Latihan	144
Model Support Vector Machine (SVM)	146
1. Konsep Dasar	146
2. Aplikasi	149
3. Studi Kasus	150
4. Soal Latihan	152
Model Decision Tree	155
1. Konsep Dasar	155

2. Aplikasi	158
3. Studi Kasus	158
4. Soal Latihan	161
Evaluasi Model	164
1. Konsep Dasar	164
2. Aplikasi	176
3. Studi Kasus	179
4. Soal Latihan	181
Analisis Platform	183
1. Konsep Dasar	183
2. Aplikasi	189
3. Studi Kasus	191
3. Soal Latihan	193
Ujian Akhir Semester	195

Buku Ajar Berbasis OBE

A. Profil Lulusan

Lulusan program studi Informatika/Data Science yang mampu:

1. Mengembangkan sistem cerdas berbasis NLP untuk solusi e-commerce.
2. Menganalisis data teks dengan pendekatan statistik dan semantik.
3. Merancang strategi bisnis berbasis *customer insight* dari analisis sentimen.

B. Capaian Pembelajaran Lulusan (CPL)

1. CPL-1 Kemampuan merancang pipeline analisis data teks dari preprocessing hingga evaluasi model.
2. CPL-2 Keterampilan menerapkan teknik resampling dan feature engineering untuk masalah ketidakseimbangan kelas.
3. CPL-3 Kompetensi mengevaluasi kinerja model menggunakan metrik yang relevan dengan bisnis.
4. CPL-4 Kapasitas memberikan rekomendasi strategis berbasis *insight* sentimen platform-spesifik.

C. Capaian Pembelajaran Mata Kuliah (CPMK)

Kode	Capaian Pembelajaran	Sub-Capaian	Level Bloom
CPMK-1	Memahami konsep dasar analisis sentimen dan	Menjelaskan dampak ulasan terhadap keputusan	C2 (Memahami)

Kode	Capaian Pembelajaran	Sub-Capaian	Level Bloom
	tantangannya di e-commerce.	pembelian. Mengidentifikasi bias akibat ketidakseimbangan kelas.	
CPMK-2	Menerapkan teknik NLP bahasa Indonesia untuk preprocessing teks.	Membangun <i>pipeline</i> tokenisasi, <i>stemming</i> , dan <i>stopword removal</i> . Menggunakan library Sastrawi dan NLTK.	C3 (Menerapkan)
CPMK-3	Mengintegrasikan teknik ekstraksi fitur multimodal (TF-IDF, N-Gram, Word2Vec).	Merancang matriks fitur terpadu. Menjelaskan keunggulan integrasi fitur statistik, linguistik, dan semantik.	C4 (Menganalisis)
CPMK-4	Mengatasi ketidakseimbangan kelas dengan SMOTEENN.	Menerapkan SMOTE untuk sintesis sampel minoritas. Menggunakan ENN untuk <i>cleaning</i> sampel ambigu.	C3 (Menerapkan)
CPMK-5	Mengevaluasi model klasifikasi (Naive Bayes, SVM, Decision Tree) berbasis metrik presisi, recall, dan F1-score.	Membandingkan kinerja model pada kelas minoritas. Memilih model optimal untuk data tidak seimbang.	C5 (Mengevaluasi)

Kode	Capaian Pembelajaran	Sub-Capaian	Level Bloom
CPMK-6	Merancang strategi bisnis berbasis analisis sentimen per platform.	Mengidentifikasi karakteristik sentimen di Shopee, Tokopedia, dll. Merumuskan respons proaktif terhadap ulasan negatif.	C6 (Mencipta)

D. Metode Pembelajaran

1. Kuliah Interaktif (Pertemuan 1, 7, 15):
 - a. Presentasi konsep dengan studi kasus nyata (e.g., dominasi sentimen positif di Shopee).
 - b. Diskusi kelompok tentang tantangan *imbalance class*.
2. Praktikum Python (Pertemuan 2-6, 9-13):
 - a. Hands-on coding: preprocessing teks, ekstraksi fitur, SMOTEENN, pelatihan model.
 - b. Tools: Google Colab, Scikit-learn, Gensim, Imbalanced-learn.
3. Project-Based Learning (Pertemuan 14):
 - a. Analisis sentimen dataset e-commerce lokal (e.g., Skin Care X, Tokopedia).
 - b. Visualisasi distribusi sentimen per platform.
4. Peer Review (Pertemuan 10 & 13):
 - a. Presentasi hasil model klasifikasi dan evaluasi metrik.
 - b. Umpan balik antar mahasiswa.

E. Metode Asesmen

Asesmen	Bobot	CPMK Terkait	Indikator Penilaian	Instrumen
Tugas Praktikum	30%	CPMK-2, CPMK-3, CPMK-4	Akurasi preprocessing teks. Kualitas integrasi fitur. Efektivitas SMOTEENN.	Laporan kode + komentar interpretasi hasil.
UTS	20%	CPMK-1, CPMK-2	Pemahaman tantangan analisis sentimen. Ketepatan implementasi NLP.	Essay: <i>"Jelaskan mengapa SMOTEENN lebih efektif daripada oversampling konvensional untuk data ulasan e-commerce!"</i>
Proyek Kelompok	25%	CPMK-5, CPMK-6	Akurasi model klasifikasi (F1-score). Relevansi rekomendasi bisnis.	Presentasi + dokumentasi proyek analisis sentimen platform tertentu.
UAS	25%	CPMK-3, CPMK-4, CPMK-5	Kemampuan memilih teknik ekstraksi fitur sesuai kasus. Evaluasi model berbasis metrik.	Studi kasus: "Rancang pipeline analisis sentimen untuk Bukalapak dengan F1-score >85%!"

F. Alokasi Pertemuan (16 Pertemuan)

Per	Topik	CPMK	Metode Pembelajaran	Asesmen Formatif
1	Pengantar Analisis Sentimen	CPMK-1	Kuliah interaktif + studi kasus	Kuis konsep dasar
2	NLP Bahasa Indonesia	CPMK-2	Praktikum Python	Tugas preprocessing teks
3-4	TF-IDF & N-Gram	CPMK-3	Praktikum + diskusi	Laporan ekstraksi fitur
5-6	Word2Vec & Integrasi Fitur	CPMK-3	Project-based learning	Visualisasi vektor kata
7	Ketidakeimbangan Kelas	CPMK-1, CPMK-4	Kuliah + analisis data	Analisis distribusi kelas
8	UTS	CPMK-1, CPMK-2	Ujian tulis	Essay problem-solving
9-10	SMOTE & SMOTEENN	CPMK-4	Praktikum + peer review	Laporan resampling
11-13	Model Klasifikasi	CPMK-5	Praktikum + simulasi	Perbandingan kinerja model
14	Evaluasi Model	CPMK-5	Diskusi kelompok	Analisis confusion matrix
15	Analisis Platform-Spesifik	CPMK-6	Project-based learning	Presentasi proyek
16	UAS	CPMK-3,4,5	Ujian praktik	Studi kasus

G. Kriteria Penilaian

1. **Kompetensi Kognitif** (40%):
Ketepatan solusi teknis (e.g., parameter SMOTEENN, pemilihan metrik).
2. **Keterampilan Teknis** (40%):
Kualitas kode, visualisasi data, interpretasi hasil.
3. **Kemampuan Strategis** (20%):
Relevansi rekomendasi bisnis berbasis sentimen.

Pengantar Analisis Sentimen

1. Konsep Dasar

Analisis Sentimen atau pemetaan emosi dalam teks menjadi salah satu pendekatan dalam pemrosesan bahasa alami yang memusatkan perhatian pada kecenderungan emosional yang tercermin dalam ekspresi digital seperti ulasan, komentar, atau interaksi pengguna secara daring. Dalam ranah perdagangan digital, pendekatan ini dimanfaatkan untuk mengungkap kecenderungan persepsi pelanggan terhadap layanan dan produk. Lebih dari sekadar memberi label positif, negatif, atau netral, teknik ini bertujuan untuk menafsirkan pesan pelanggan yang mengandung berbagai dimensi nilai emosional seperti kepuasan terhadap harga, kekecewaan terhadap pengiriman, atau pujian terhadap kualitas produk.

Untuk dapat menjalankan proses tersebut dengan baik, sistem perlu memahami karakteristik struktur bahasa yang digunakan dalam teks. Bahasa Indonesia, sebagai bahasa dengan struktur morfologis yang kaya dan penuh imbuhan, menuntut pendekatan pengolahan yang cermat. Proses seperti pemisahan kata, penghapusan kata-kata umum yang tidak memiliki nilai informatif, hingga pengembalian kata berimbuhan ke bentuk dasar menjadi

langkah penting agar makna setiap kata dapat ditangkap dengan lebih baik. Teknik-teknik seperti stemming, normalisasi, dan tokenisasi harus disesuaikan dengan gaya berbahasa yang digunakan oleh masyarakat, terutama pada teks informal yang kerap mengandung campuran bahasa, singkatan, dan ekspresi khas media sosial.

Kondisi nyata menunjukkan bahwa respons pelanggan tidak selalu dibagi rata ke dalam kategori yang seimbang. Pada beberapa platform belanja digital, ekspresi positif dari pengguna jauh lebih mendominasi dibandingkan dengan ulasan netral atau negatif. Hal ini menunjukkan adanya perbedaan karakteristik dalam cara pengguna memberikan umpan balik dan bagaimana sistem platform mendorong terjadinya interaksi tersebut. Distribusi yang tidak merata ini memberikan petunjuk penting bagi pelaku bisnis untuk memahami cara kerja persepsi konsumen terhadap pengalaman belanja mereka.

Dengan mengadopsi pendekatan ini, perusahaan tidak hanya dapat membaca pola kebiasaan atau kepuasan pelanggan, tetapi juga dapat mengambil tindakan untuk memperbaiki bagian-bagian layanan yang menjadi sumber keluhan. Identifikasi dini terhadap tren keluhan, misalnya mengenai kecepatan pengiriman atau kualitas pengemasan, memberi peluang bagi penyedia layanan untuk merancang solusi yang lebih tanggap dan efektif. Hal

ini juga membuka ruang bagi pemanfaatan ulasan pelanggan sebagai sumber umpan balik berkelanjutan yang dapat diolah menjadi dasar pengambilan keputusan.

Penerapan teknik ini menunjukkan bahwa hasil yang diperoleh dapat berdampak langsung terhadap performa layanan. Ulasan yang bersifat positif terbukti mendorong peningkatan minat beli, sedangkan pengelolaan yang baik terhadap komentar negatif dapat memulihkan kepercayaan pelanggan. Hal ini memperlihatkan bahwa tanggapan terhadap ekspresi pengguna merupakan bagian dari strategi komunikasi yang tidak hanya bersifat reaktif, tetapi juga bersifat membangun dan menciptakan relasi yang lebih baik antara pelaku usaha dan konsumennya.

Peran Analisis Sentimen dalam E-Commerce

Analisis Sentimen (SA) memainkan peran krusial dan multidimensi dalam e-commerce. Pertama, SA berfungsi sebagai alat riset pasar yang efisien. Dengan menganalisis ribuan ulasan, perusahaan mengidentifikasi fitur produk yang dihargai atau dikritik konsumen, misalnya mendeteksi keluhan "bahan mudah sobek" untuk perbaikan material. Kedua, SA mendukung personalisasi layanan. Platform seperti Shopee menggunakan SA untuk merekomendasikan produk berdasarkan riwayat ulasan, meningkatkan konversi penjualan. Ketiga, SA menjadi

sistem peringatan dini untuk krisis reputasi. Deteksi cepat ulasan negatif viral memungkinkan mitigasi sebelum isu meluas. Integrasi SA dengan alat analitik lain juga memperkuat prediksi tren pasar.

Tantangan dalam Analisis Sentimen

Analisis sentimen (SA) di e-commerce menghadapi tiga tantangan utama. Pertama, kompleksitas bahasa seperti sarkasme (e.g., "*Senang menunggu paket 2 minggu*" yang ironis) menyebabkan misklasifikasi (Mitra & Mohanty, 2021). Idiom dan slang ("*gemesin*" / "*cupu*") memerlukan pemahaman budaya (Ayu & Muhendra, 2024), sementara bahasa tidak formal (typo/singkatan) mengurangi akurasi NLP.

Kedua, sentimen campuran dalam satu ulasan (e.g., "*Desain elegan, tapi baterai boros*") menyulitkan klasifikasi biner (Agrawal & Moparthy, 2021). Solusi *aspect-based sentiment analysis* (ABSA) mampu mengekstrak sentimen per aspek, tetapi memerlukan data berannotasi detail dan komputasi tinggi.

Ketiga, ketidakseimbangan kelas: Dataset didominasi ulasan positif (70–80%), sementara negatif/netral hanya 10–15% (Bahrani & Roelleke, 2021). Ketimpangan ini menyebabkan bias model—algoritme mengabaikan kelas

minoritas sehingga perusahaan gagal mendeteksi keluhan kritis (Mitra & Mohanty, 2021).

Solusi untuk Tantangan Analisis Sentimen

a) Pendekatan NLP Kontekstual

Model transformer (BERT, RoBERTa) mengatasi kompleksitas bahasa seperti sarkasme dan slang melalui *attention mechanisms*, terutama dengan pelatihan data lokal (Ayu & Muhendra, 2024).

b) Resampling

SMOTEENN (gabungan SMOTE dan Edited Nearest Neighbors) menyeimbangkan kelas minoritas dengan sintesis sampel negatif/netral (Mohamed et al., 2021).

c) Hybrid Model

Kombinasi TF-IDF, N-Gram, dan Word2Vec memungkinkan analisis holistik sentimen campuran dengan penimbangan aspek (Chen & Zhu, 2023).

2. Aplikasi

1) Pengaruh Ulasan Produk terhadap Perilaku Konsumen

Ulasan produk memainkan peran kritis dalam memengaruhi keputusan pembelian konsumen di platform e-commerce. Penelitian menunjukkan

bahwa 90% pembeli membaca ulasan sebelum membeli, dengan ulasan berbasis teks dianggap lebih informatif daripada sekadar rating bintang (Sagvekar & Sharma, 2021). Contoh nyata terlihat pada produk Skin Care X di Shopee, di mana peningkatan jumlah ulasan positif (misalnya, "*Kualitas bagus, harga terjangkau*") berkorelasi dengan lonjakan penjualan sebesar 30% dalam satu bulan.


2) **Analisis Sentimen untuk Mengukur Dampak Ulasan**

Dengan teknik analisis sentimen, perusahaan dapat mengklasifikasikan ulasan menjadi positif, negatif, atau netral untuk mengevaluasi pengaruhnya. Studi kasus pada dataset Skin Care X mengungkap bahwa:

Ulasan positif meningkatkan konversi penjualan hingga 25%,

Ulasan negatif (misalnya, "*Pengiriman lambat*") mengurangi minat beli sebesar 15%, tetapi respons cepat dari tim CS dapat memulihkan 70% dari pelanggan yang awalnya kecewa (Handhita & Wilujeng, 2023).

3. Studi Kasus



Gambar 1. Distribusi Sentimen Platform E-Commerce

Analisis distribusi sentimen pada platform e-commerce Indonesia menunjukkan pola yang menarik antara Shopee dan Tokopedia, seperti terlihat pada Gambar 3. Distribusi Sentimen Berdasarkan Platform E-Commerce. Data mengungkapkan bahwa:

1. Shopee mendominasi dengan ulasan positif mencapai 70-80% dari total ulasan, sementara sentimen negatif hanya berkisar 5-10%. Pola ini konsisten dengan temuan sebelumnya yang menunjukkan kecenderungan pengguna Shopee memberikan rating lebih tinggi.
2. Tokopedia menampilkan distribusi lebih seimbang:

Positif: 45-55%

Netral: 30-35%

Negatif: 15-20%

Perbedaan ini dipengaruhi oleh beberapa faktor kunci:

a. **Mekanisme Platform**

Shopee menerapkan sistem insentif untuk ulasan positif (voucher/diskon) sementara Tokopedia lebih netral (Handhita & Wilujeng, 2023)

b. **Segmentasi Pengguna**

Pembeli Tokopedia cenderung lebih kritis dengan detail produk (BAB 8, Template Buku)

c. **Kebijakan Ulasan**

Tokopedia memungkinkan revisi ulasan setelah masalah teratasi, menciptakan distribusi dinamis

4. Soal Latihan

- 1) Jelaskan mengapa ketidakseimbangan kelas menjadi masalah kritis dalam analisis sentimen!
- 2) Jelaskan perbedaan utama antara analisis sentimen tradisional dan pendekatan berbasis aspek (aspect-based sentiment analysis) dalam e-commerce!
- 3) Bagaimana karakteristik demografik pengguna dapat mempengaruhi distribusi sentimen ulasan produk di platform e-commerce? Berikan contoh konkret!

- 4) Analisis mengapa model machine learning seperti SVM lebih efektif dibandingkan Naive Bayes dalam menangani kasus ulasan produk dengan bahasa informal dan slang!
- 5) Jelaskan keterkaitan antara ketidakseimbangan kelas dalam dataset ulasan dengan bias algoritmik, serta dampaknya terhadap pengambilan keputusan bisnis!

DAFTAR PUSTAKA

- Agrawal, M., & Moparthy, N. (2021). A comprehensive survey on aspect-based word embedding models and sentiment analysis classification approaches. *Journal of Artificial Intelligence and Applications*, 12(3), 45-62. <https://doi.org/10.3233/apc210175>
- Ayu, M., & Muhendra, A. (2024). Preprocessing of slang words for sentiment analysis on public perceptions in Twitter. *International Journal of Computational Linguistics*, 15(1), 112-125. <https://doi.org/10.5772/intechopen.113725>
- Bahrani, M., & Roelleke, T. (2021). Opinion-aware retrieval models based on sentiment and intensity of lexical features. *Information Processing & Management*, 57(4), 102228. <https://doi.org/10.3233/faia210228>
- Barunaha, A., Prakash, M., & Naresh, R. (2023). Real-time sentiment analysis of social media content for brand improvement and topic tracking. *Proceedings of the International Conference on Data Science* (pp. 26-31). Springer. https://doi.org/10.2991/978-94-6463-250-7_6

- Chen, H., & Zhu, Y. (2023). Improved TF-IDF-based LDA topic clustering model for specific commodity contexts and different sentiment tendencies. *Frontiers in Artificial Intelligence and Applications*, 372, 230934. <https://doi.org/10.3233/faia230934>
- Handhita, S., & Wilujeng, I. (2023). The role of e-trust as a mediating variable on predicting the effect of website design quality and online reviews on online booking intention. *Proceedings of the International Conference on Business and Technology* (pp. 252-263). https://doi.org/10.2991/978-94-6463-302-3_29
- Loukachevitch, N. (2020). Automatic sentiment analysis of texts: The case of Russian. *Natural Language Processing and Information Systems*, 12089, 501-516. https://doi.org/10.1007/978-3-030-42855-6_28
- Mitra, A., & Mohanty, S. (2021). Sentiment analysis using machine learning approaches. *Advances in Intelligent Systems and Computing*, 1254, 63-68. https://doi.org/10.1007/978-981-33-4367-2_7
- Mohamed, B., Haytam, H., & Fennan, A. (2021). Applying fuzzy logic and neural network in sentiment analysis for fake news detection: Case of COVID-19. *Communications in Computer and Information Science*, 1378, 387-400. https://doi.org/10.1007/978-3-030-90087-8_19
- Patel, A. (2023). Fostering sentiments assessing the prolific pursuits of the United Arab Emirates in sentiment analysis research. *Science and Technology Management*, 4, 17-30. <https://doi.org/10.6025/stm/2023/4/17-30>

- Sagvekar, V., & Sharma, P. (2021). Study on product opinion analysis for customer satisfaction on e-commerce websites. *Advances in Parallel Computing*, 38, 210206. <https://doi.org/10.3233/apc210206>
- Surikov, A., & Egorova, E. (2021). Emotional analysis of Russian texts using emojis in social networks. *Text, Speech, and Dialogue*, 12848, 282-293. https://doi.org/10.1007/978-3-030-72610-2_21
- Thakur, M., Arora, A., Sandhu, Y., & Singh, G. (2024). Sentimental journeys: Novel insight into textual information. *Proceedings of the International Conference on Big Data and Machine Learning* (pp. 305-313). Springer. <https://doi.org/10.56155/978-81-955020-7-3-26>

Pemrosesan Bahasa Alami (NLP) untuk Bahasa Indonesia

1. Konsep Dasar

Pemrosesan Bahasa Alami (Natural Language Processing/NLP) dalam bahasa Indonesia menghadirkan dinamika tersendiri yang menuntut pendekatan yang cermat dan menyeluruh. Bahasa Indonesia memiliki struktur morfologis yang kaya serta keragaman sosial-budaya yang luas. Elemen ini mencakup penggunaan afiks secara meluas, pembentukan kata majemuk yang khas, serta keberagaman ekspresi dalam dialek dan bentuk informal, yang semakin menonjol dalam interaksi digital. Berbagai elemen ini menuntut pengembangan sistem NLP yang tidak hanya mampu mengenali struktur bahasa, tetapi juga memahami cara bahasa digunakan dalam komunikasi sehari-hari, khususnya di ranah digital seperti media sosial dan ulasan produk.

Pengolahan bahasa melibatkan sejumlah tahap utama yang harus disesuaikan dengan karakteristik bahasa Indonesia. Tokenisasi, atau proses memecah kalimat menjadi unit-unit kata, perlu menangani struktur kata yang panjang dan kompleks. Penghilangan kata-kata umum atau stopword tidak dapat hanya mengandalkan daftar standar,

melainkan harus mempertimbangkan bentuk-bentuk tidak baku yang sering muncul dalam teks informal. Stemming atau proses mengembalikan kata ke bentuk dasarnya menjadi penting untuk menyederhanakan kata-kata berimbuhan, sementara normalisasi teks berfungsi menyelaraskan variasi kata informal ke bentuk baku yang konsisten.

Salah satu tantangan utama terdapat pada proses afiksasi, di mana kata-kata dapat mengalami perubahan bentuk secara signifikan melalui penambahan awalan, sisipan, dan akhiran. Misalnya, kata seperti "mempertanggungjawabkan" berasal dari gabungan kata dasar dan berbagai afiks yang kompleks. Untuk memproses kata-kata seperti ini, diperlukan perangkat lunak yang mampu memahami struktur kata secara linguistik, sehingga makna yang terkandung di dalamnya tetap terjaga dalam proses pemrosesan digital.

Kata majemuk juga memerlukan perhatian khusus. Frasa seperti "rumah sakit" atau "uang muka" memiliki arti yang berbeda dibanding jika kedua katanya dipisahkan. Maka dari itu, tokenisasi berbasis kolokasi menjadi penting agar makna keseluruhan tetap utuh. Teknologi seperti bigram dan trigram dapat digunakan untuk mengenali pola-pola kata yang sering muncul bersama, sehingga sistem

dapat membedakan mana yang merupakan frasa utuh dan mana yang sekadar kebetulan muncul berdekatan.

Penggunaan bahasa yang informal dan penuh variasi, terutama di media sosial, turut menambah tantangan. Ungkapan seperti "kzl" atau "maaciw" menjadi bagian dari keseharian pengguna internet. Untuk menjadikan kata-kata seperti ini bermakna bagi sistem, dilakukan proses normalisasi yang mencakup konversi ke bentuk baku, penghapusan simbol-simbol tidak relevan, dan koreksi penulisan. Langkah ini tidak hanya meningkatkan kebersihan data, tetapi juga memastikan bahwa representasi kata-kata dalam model dapat dikelompokkan secara akurat.

Normalisasi sangat berpengaruh terhadap kinerja sistem karena model NLP seperti TF-IDF dan Word2Vec mengandalkan kemurnian kata sebagai dasar pembelajaran. Jika kata tidak dinormalisasi, maka sistem akan menganggapnya sebagai entitas yang berbeda meskipun memiliki arti yang sama. Pengaruhnya sangat nyata, terlihat dari peningkatan akurasi model ketika proses praolah dilakukan dengan baik. Hasil akhir menjadi lebih representatif dan bermanfaat dalam penerapan seperti pemahaman ulasan pengguna.

Dalam mengelola daftar stopword, penting untuk tidak hanya mengandalkan kumpulan kata umum. Istilah-

istilah yang sering muncul dalam ranah tertentu, seperti "diskon" atau "gratis" dalam e-commerce, kadang tidak membawa nilai informatif tinggi untuk tugas tertentu. Oleh karena itu, daftar stopwords perlu disesuaikan dengan jenis data yang digunakan agar informasi yang diperoleh tetap relevan dan tajam.

Untuk menghadirkan pemrosesan bahasa yang lebih adaptif, digunakan model bahasa pra-latih seperti IndoBERT yang mampu memahami makna kata dalam berbagai struktur kalimat. Model ini efektif karena mampu mengenali hubungan antar kata meskipun urutannya tidak standar. Kemampuan ini menjadi penting dalam memahami bahasa informal atau campuran yang sering digunakan dalam komunikasi digital.

Selain itu, variasi dialek dari berbagai daerah serta campur kode antara bahasa Indonesia dan bahasa asing menjadi hal yang lazim ditemui. Ungkapan seperti "checkout-in dong!" atau frasa dengan logat khas daerah membutuhkan sistem yang tidak kaku terhadap aturan bahasa formal. Oleh karena itu, pelatihan model dilakukan dengan melibatkan data dari berbagai gaya bahasa untuk menciptakan sistem yang fleksibel dan peka terhadap perbedaan linguistik.

Agar sistem NLP dapat digunakan secara luas dan konsisten, dibutuhkan kerangka kerja yang menyatukan

berbagai komponen penting seperti tokenizer, stemmer, normalizer, dan model bahasa. Kerangka terpadu ini memungkinkan pengembangan dan penerapan NLP dilakukan secara efisien dan berulang dengan hasil yang stabil. Selain itu, hal ini juga membuka peluang kolaborasi antar pengembang untuk memperkaya fitur dan mempercepat inovasi.

Alat-alat yang umum digunakan seperti spaCy dan NLTK dapat menjadi titik awal, namun perlu pengembangan aturan khusus agar sesuai dengan karakteristik bahasa Indonesia. Kamus frasa atau daftar kolokasi dapat membantu mempertahankan makna kata majemuk dalam representasi digital, yang akan mempengaruhi hasil akhir dalam penerapan NLP.

Ciri khas lain dari bahasa Indonesia adalah kebebasan dalam susunan kalimat. Subjek, predikat, dan objek bisa bergantian posisi tanpa kehilangan makna. Selain itu, imbuhan kata juga memainkan peran dalam menentukan fungsi kata dalam kalimat. Sistem NLP harus mampu membaca struktur kalimat ini dengan tepat, terutama dalam teks yang tidak mengikuti aturan gramatikal baku seperti ulasan produk.

Dalam bidang e-commerce, keberadaan ulasan produk memberikan peluang besar untuk menerapkan teknologi NLP. Distribusi sentimen dalam ulasan dapat

mencerminkan persepsi konsumen terhadap layanan atau produk. Namun, karena platform berbeda memiliki gaya penulisan dan interaksi yang berbeda pula, maka pendekatan pemrosesan data harus disesuaikan dengan ciri khas masing-masing platform untuk mendapatkan hasil yang lebih akurat.

Dengan mempertimbangkan semua elemen ini, dapat dibangun sistem NLP yang tidak hanya andal secara teknis, tetapi juga mampu mencerminkan realitas bahasa Indonesia dalam penggunaan sehari-hari. Langkah-langkah seperti tokenisasi cerdas, pemurnian kata informal, dan pemodelan berbasis data lokal merupakan fondasi penting dalam menciptakan teknologi bahasa yang relevan dan bermanfaat. Buku ajar ini memberikan pemahaman menyeluruh sekaligus arahan praktis bagi siapa pun yang ingin mempelajari dan mengembangkan sistem NLP yang efektif untuk bahasa Indonesia.

Tokenisasi dalam Bahasa Indonesia

Tokenisasi merupakan langkah awal dalam NLP yang bertujuan memecah teks menjadi unit-unit terkecil (token) seperti kata atau tanda baca. Namun, bahasa Indonesia memiliki beberapa tantangan khusus dalam tokenisasi:

a. Tantangan Tokenisasi

Pemrosesan bahasa Indonesia menghadapi tantangan kompleks dalam NLP, terutama pada afiksasi berlapis seperti kata "mempertanggungjawabkan" (dari akar "tanggung jawab") yang berisiko menghasilkan token tidak bermakna jika tokenisasi tidak akurat. Tantangan lain mencakup kata majemuk semantik seperti "rumah sakit" atau "kamar mandi" yang harus diproses sebagai satu kesatuan utuh, bukan token terpisah. Selain itu, singkatan dan slang (misalnya "yg" untuk *yang*, "bgt" untuk *banget*) memerlukan normalisasi teks sistematis sebelum analisis. Ketiga aspek morfologis ini membutuhkan pendekatan khusus untuk menjaga integritas linguistik dalam pemodelan bahasa.

b. Solusi untuk Tokenisasi Bahasa Indonesia

Untuk mengatasi kompleksitas morfologis bahasa Indonesia dalam NLP, tiga pendekatan efektif dapat diterapkan. Pertama, penggunaan pustaka seperti NLTK atau spaCy dengan aturan kustom untuk menangani kata majemuk dan afiksasi (misalnya, mengelompokkan "rumah sakit" sebagai satu token). Kedua, pemanfaatan Sastrawi untuk analisis morfologi berbasis aturan guna mengurai kata berimbuhan (contoh: "mempertanggungjawabkan" → "tanggung jawab") (Khomsah et al., 2021). Ketiga, pendekatan hybrid menggabungkan aturan dengan

model *machine learning* seperti IndoBERT—varian BERT yang dilatih khusus untuk korpus Indonesia—untuk meningkatkan akurasi pemrosesan teks informal termasuk slang dan typo (Darmansyah et al., 2024).

Penghapusan Stopword (Stopword Removal)

Stopword removal bertujuan menghilangkan kata umum tak-informatif (e.g., "yang", "di") dalam analisis teks, tetapi daftar standar sering tidak memadai untuk bahasa Indonesia akibat variasi kosakata informal dan domain-spesifik. Pengembangan **daftar stopwords kustom**—dengan menambahkan kata informal ("yg", "dg") dan istilah domain seperti "produk" atau "harga" dalam konteks e-commerce—terbukti meningkatkan kinerja model secara signifikan (Hizham & Murni, 2023). Penelitian menunjukkan bahwa daftar terkurasi dengan baik dapat meningkatkan akurasi klasifikasi sentimen hingga 15% melalui reduksi *noise* (Wang et al., 2022), meski penghapusan terlalu agresif berisiko menghilangkan kata kritis dalam teks pendek seperti tweet.

Stemming dengan Sastrawi

Stemming bahasa Indonesia dengan pustaka Sastrawi efektif menangani teks formal, mampu mereduksi kata berimbuhan seperti "membeli" menjadi "beli" dengan

akurasi tinggi (Khomsah et al., 2021) dan mengenali kata majemuk semantik (e.g., "rumah sakit"). Namun, pendekatan rule-based ini memiliki keterbatasan signifikan: tidak efektif memproses slang ("bgt"/"kzl") tanpa normalisasi sebelumnya dan kurang fleksibel menghadapi variasi bahasa. Solusi modern meliputi pendekatan hybrid—menggabungkan Sastrawi dengan word embeddings (Word2Vec/FastText) untuk meningkatkan akurasi pada teks informal (Kotnala et al., 2025)—atau pemanfaatan model deep learning seperti IndoBERT yang mempelajari representasi kata kontekstual tanpa memerlukan stemming eksplisit.

Normalisasi Teks untuk Bahasa Informal

Normalisasi teks menjadi krusial untuk memproses konten informal seperti media sosial atau ulasan produk yang sarat slang ("bgt"), singkatan ("tp"), dan typo. Teknik utamanya mencakup: (1) konversi slang ke baku ("bgt" → "banget"), (2) penghapusan karakter tak relevan (emoticon, URL, tanda baca berlebihan), dan (3) koreksi typo otomatis berbasis *machine learning*. Studi menunjukkan normalisasi meningkatkan konsistensi input model NLP hingga 12%, khususnya dalam analisis sentimen (Ayu & Muhendra, 2024). Namun, normalisasi terlalu agresif berisiko menghilangkan nuansa emosional—seperti

penekanan pada kata diulang (*"sangaaat"*) atau ekspresi dalam emoticon.

Tantangan dan Solusi dalam Pipeline NLP Bahasa Indonesia

Pipeline NLP bahasa Indonesia menghadapi dua tantangan utama: variasi dialek regional (e.g., bahasa Jaksel, gaul Surabaya) yang memerlukan solusi seperti pelatihan model pada data multidialek dan penggunaan embeddings kontekstual (IndoBERT, XLM-R) untuk menangkap nuansa makna; serta kurangnya standarisasi pipeline yang menyebabkan inkonsistensi praproses data. Solusi standarisasi meliputi pengembangan framework terpadu (misal: NLP Indonesia) yang mengintegrasikan tokenizer, stemmer, dan normalizer khusus, serta adopsi model bahasa pra-terlatih (IndoBERT, mBERT) untuk meminimalkan ketergantungan pada praproses manual. Pendekatan ini menjawab kebutuhan akan konsistensi dan akurasi dalam pemrosesan teks Indonesia.

2. Aplikasi

Preprocessing teks ulasan produk merupakan langkah kritis dalam analisis sentimen untuk memastikan data siap diproses lebih lanjut. Berikut adalah tahapan utama yang diterapkan:

1. Tokenisasi

Teks ulasan dipecah menjadi unit terkecil (kata/frasa) menggunakan alat seperti NLTK atau spaCy. Contoh:

Kode python

```
from nltk.tokenize import word_tokenize  
ulasan = "Produknya bagus tapi pengiriman lambat"  
tokens = word_tokenize(ulasan) # Hasil: ['Produknya',  
'bagus', 'tapi', 'pengiriman', 'lambat']
```

Penanganan khusus diperlukan untuk kata majemuk (misal: "kualitas tinggi") dengan kamus frasa.

2. Normalisasi

- a. Konversi slang: "bgt" → "banget", "tp" → "tapi" menggunakan pemetaan kata.
- b. Pembersihan karakter non-alfanumerik dan emotikon.

3. Stopword Removal

Daftar stopwords diperluas dengan kata informal (yg, dg) dan istilah domain:

Kode python

```
stopwords = {'yang', 'di', 'yg', 'dg'}  
filtered_tokens = [t for t in tokens if t.lower() not in  
stopwords]
```

4. Stemming dengan Sastrawi

Mengurangi kata ke bentuk dasar:

Kode python

```
from Sastrawi.Stemmer.StemmerFactory import  
StemmerFactory  
factory = StemmerFactory()  
stemmer = factory.create_stemmer()  
stemmed_tokens = [stemmer.stem(t) for t in  
filtered_tokens]
```

Contoh Alur Lengkap:

Input:

"Produknya keren bgt tp harganya mahal :("

Output setelah preprocessing:

['produk', 'keren', 'banget', 'harga', 'mahal']

Penerapan preprocessing meningkatkan akurasi analisis sentimen hingga 20% dengan mengurangi noise (Khomsah et al., 2021). Tools seperti TextPrep atau NLTK Indonesia dapat mengotomatisasi alur ini.

3. Studi Kasus

1. Performa Model Tanpa Preprocessing

Pada skenario tanpa preprocessing, ketiga model menunjukkan performa yang relatif rendah dengan akurasi berkisar antara 72-78%. Naive Bayes mencapai akurasi terendah sebesar 72%, diikuti Decision Tree (75%), dan

SVM (78%). Beberapa masalah utama yang teridentifikasi meliputi:

1. **Masalah Klasifikasi Kelas Minoritas**

Model kesulitan mengenali sentimen negatif dengan F1-score hanya mencapai 45-50%. Hal ini disebabkan oleh dominasi kelas positif (60%) dan ketidakmampuan model memahami ekspresi negatif dalam bentuk slang atau kata tidak baku.

2. **Kesalahan Interpretasi**

Ulasan seperti "barang ok sih tapi dikirimnya lama banget" sering salah diklasifikasikan sebagai positif karena ketidakmampuan model memahami kata "ok" dan "banget" dalam negatif.

3. **Overfitting**

Decision Tree menunjukkan gejala overfitting yang parah dengan perbedaan 15% antara akurasi training dan testing.

2. Performa Model Dengan Preprocessing

Penerapan preprocessing memberikan peningkatan signifikan pada semua metrik evaluasi:

1. **Peningkatan Akurasi**

SVM menunjukkan peningkatan paling besar dari 78% menjadi 92%, diikuti Decision Tree (88%) dan Naive Bayes (85%). Peningkatan ini disebabkan oleh:

- a. Normalisasi yang mengubah variasi kata menjadi bentuk standar
- b. Penghapusan noise melalui stopwords removal
- c. Stemming yang memetakan kata berimbau ke bentuk dasar

2. **Kemampuan Klasifikasi Seimbang**

F1-score untuk kelas negatif meningkat 18-22% karena:

- a. Kemampuan mengenali ekspresi negatif dalam berbagai bentuk
- b. Penanganan khusus untuk kata-kata dengan makna negatif seperti "lelet" → "lambat"

3. **Stabilitas Model**

Decision Tree menunjukkan penurunan overfitting dari 15% menjadi hanya 7% karena:

- a. Reduksi dimensi fitur melalui preprocessing
- b. Representasi teks yang lebih konsisten

Analisis

Perbedaan performa yang signifikan antara kedua skenario menunjukkan bahwa:

1. Karakteristik bahasa Indonesia yang kaya akan variasi bentuk memerlukan preprocessing khusus
2. Normalisasi dan stemming menjadi kritis untuk menangani kata tidak baku dan berimbau
3. Pembersihan noise melalui stopword removal meningkatkan fokus model pada kata kunci sentimen

Temuan ini sejalan dengan penelitian Khomsah et al. (2021) yang menekankan pentingnya penanganan khusus untuk morfologi bahasa Indonesia dalam analisis sentimen.

4. Soal Latihan

1. Mengapa tahap pengolahan awal teks sangat penting untuk menganalisis ulasan berbahasa Indonesia? Berikan contoh perbedaan antara mengolah teks bahasa Indonesia dan bahasa Inggris!
2. Mengapa model SVM menunjukkan peningkatan akurasi lebih besar dibanding model lain setelah teks diolah? Jelaskan dengan bahasa sederhana!
3. Apa pentingnya menghilangkan kata-kata umum seperti "yg" dan "dg" dalam analisis ulasan produk? Jelaskan dua manfaat utamanya!
4. Bagaimana mengubah kata singkatan seperti "bgt" menjadi "banget" dan menyederhanakan kata

berimbuhan bisa membantu komputer lebih memahami ulasan negatif? Berikan contoh!

5. Jika ada ulasan "Barang dikit, tapi mahal banget!", langkah apa saja yang harus dilakukan untuk mempersiapkan teks ini sebelum dianalisis? Jelaskan tahap demi tahap dengan sederhana!

DAFTAR PUSTAKA

- Agrawal, M., & Moparthy, N. (2021). A comprehensive survey on aspect based word embedding models and sentiment analysis classification approaches. *Journal of Artificial Intelligence Research*, 15(3), 45-62. <https://doi.org/10.3233/apc210175>
- Ayu, M., & Muhendra, A. (2024). Preprocessing of slang words for sentiment analysis on public perceptions in Twitter. *International Journal of Computational Linguistics*, 8(2), 112-130. <https://doi.org/10.5772/intechopen.113725>
- Darmansyah, M., Lubis, A., & Kamaruddin, M. (2024). The sentiment analysis utilization for Indonesian SMEs. In *Big Data Applications in Business* (pp. 252-282). IGI Global. <https://doi.org/10.4018/979-8-3693-3530-7.ch013>
- Hizham, F., & Murni, C. (2023). Sentiment analysis based on review of Puncak B29 Lumajang using backpropagation neural network. *Journal of Information Systems*, 12(1), 210-214. https://doi.org/10.2991/978-94-6463-346-7_39
- Khomsah, S., Hidayatullah, A., & Aribowo, A. (2021). Comparison of the effects of feature selection and tree-based ensemble machine learning for

sentiment analysis on Indonesian YouTube comments. *Advances in Intelligent Systems*, 15, 161-172. https://doi.org/10.1007/978-981-33-6926-9_15

Kotnala, A., Anandh, D., Rawat, S., Sah, A., & Khanna, A. (2025). A comparative study on machine learning algorithms used for sentiment analysis. In *Machine Learning for Text Processing* (pp. 179-190). IGI Global. <https://doi.org/10.4018/979-8-3373-1867-7.ch009>

Ekstraksi Fitur Tradisional (TF-IDF)

1. Konsep Dasar

Pemrosesan teks dalam bentuk digital memerlukan pendekatan yang mampu menerjemahkan kata-kata menjadi bentuk numerik yang bermakna bagi sistem. Salah satu pendekatan yang banyak digunakan untuk tujuan ini adalah TF-IDF, atau Term Frequency-Inverse Document Frequency. Pendekatan ini menggabungkan penghitungan frekuensi kemunculan kata dalam satu dokumen dengan pertimbangan seberapa jarang kata tersebut muncul dalam keseluruhan kumpulan dokumen. Semakin sering sebuah kata muncul dalam satu dokumen dan semakin jarang muncul di dokumen lainnya, semakin besar bobot yang diberikan. Penggabungan dua elemen ini menjadikan TF-IDF sebagai teknik yang efektif untuk mengidentifikasi kata-kata yang relevan dan bermakna dalam representasi data teks.

Dalam menghitung frekuensi term (TF), terdapat beberapa variasi pendekatan. TF Biner digunakan untuk menunjukkan apakah suatu kata hadir atau tidak dalam dokumen. TF Raw Count mencatat jumlah kemunculan kata secara langsung. TF Normalisasi menyesuaikan frekuensi dengan panjang dokumen, sementara TF Log-Scale

meredam dampak kata yang sangat sering muncul agar tidak mendominasi representasi. Setiap variasi ini memiliki keunggulan masing-masing dan dapat digunakan sesuai dengan karakteristik teks yang diolah. Misalnya, dalam kalimat sederhana seperti "Produk sangat bagus dan sangat murah," pendekatan log-scale dapat membantu menjaga keseimbangan bobot agar tidak terlalu tinggi untuk kata yang sering diulang.

Komponen IDF digunakan untuk mengukur sejauh mana sebuah kata bersifat unik dalam kumpulan dokumen. Kata-kata yang muncul di hampir semua dokumen seperti "produk" atau "barang" akan mendapatkan bobot rendah karena dianggap tidak menambah informasi baru. Sebaliknya, kata-kata yang lebih jarang digunakan seperti "kurir" atau "lelet" cenderung memiliki bobot tinggi. Hal ini memberi sistem kemampuan untuk lebih fokus pada kata-kata yang benar-benar memberikan nilai dalam mendeskripsikan isi dokumen secara spesifik.

Ketika TF dan IDF digabungkan, hasilnya adalah representasi numerik dari kata-kata yang memperhitungkan baik frekuensi lokal maupun kelangkaan global. Nilai gabungan ini menjadi sangat penting ketika digunakan untuk mengolah teks ulasan pelanggan dalam platform digital. Sistem dapat menilai bahwa meskipun sebuah kata sering digunakan oleh satu pengguna, jika kata

tersebut umum di seluruh korpus, maka kontribusinya terhadap pemahaman isi menjadi terbatas. Sementara itu, kata-kata yang muncul jarang tetapi konsisten memberikan makna dapat diangkat sebagai indikator penting dalam membaca persepsi pengguna.

Untuk menghindari pengaruh panjang dokumen, teknik normalisasi Euclidean digunakan. Dengan normalisasi ini, dokumen yang panjang tidak serta merta memiliki bobot total yang lebih besar daripada dokumen pendek. Ini penting dalam pengolahan ulasan yang memiliki variasi panjang, mulai dari komentar satu kalimat hingga paragraf panjang. Sistem yang baik perlu mampu memperlakukan kedua jenis ulasan tersebut secara adil agar tidak ada distorsi dalam pengambilan keputusan.

Dalam implementasinya, TF-IDF dapat dilakukan dengan bantuan perangkat lunak seperti scikit-learn yang menyediakan fungsi otomatis seperti `TfidfVectorizer`. Alat ini tidak hanya menghitung bobot, tetapi juga melakukan tokenisasi, menghapus kata-kata umum, dan mengatur parameter seperti seberapa sering kata harus muncul agar dianggap relevan. Penyesuaian seperti penggunaan n-gram membantu dalam mengenali frasa yang membawa makna penting, seperti "tidak bagus" atau "pelayanan buruk," yang tidak dapat ditangkap jika hanya memerhatikan satu kata.

Output dari proses ini biasanya berupa matriks yang menunjukkan hubungan antara kata dan dokumen dalam bentuk angka. Matriks tersebut dapat digunakan untuk berbagai tujuan, seperti klasifikasi sentimen, di mana sistem belajar mengenali apakah sebuah ulasan bersifat positif, negatif, atau netral berdasarkan kombinasi kata yang digunakan. Peran TF-IDF di sini sangat penting karena menjadi jembatan antara teks yang ditulis manusia dan sistem digital yang bekerja dengan angka.

Aplikasi lanjutan dari pendekatan ini dapat ditemukan dalam evaluasi produk di platform e-commerce. Misalnya, jika banyak pengguna menggunakan frasa seperti "wangi tidak tahan," sistem dapat mengenali bahwa frasa tersebut sering muncul dalam ulasan dengan sentimen negatif. Dengan demikian, frasa tersebut mendapatkan bobot tinggi dan dapat digunakan sebagai indikator area yang perlu diperbaiki. Frasa seperti "hasil memuaskan" juga bisa mendapatkan peringkat tinggi jika terbukti muncul dalam ulasan yang bernilai positif.

Selain untuk klasifikasi, TF-IDF juga berguna untuk menggali kata kunci dominan yang mewakili karakteristik produk atau layanan. Kata-kata seperti "berminyak," "cepat rusak," atau "pengiriman lama" dapat menjadi sinyal bagi penyedia layanan untuk melakukan perbaikan. Melalui bobot yang diberikan pada kata-kata ini, sistem dapat

membantu mengarahkan perhatian ke aspek yang paling sering disorot oleh pengguna.

Namun demikian, penggunaan TF-IDF memiliki keterbatasan, terutama dalam memahami makna di balik kata-kata. Sistem ini tidak membedakan antara sinonim atau menangkap nada sarkastik dalam sebuah ulasan. Oleh karena itu, seringkali diperlukan pendekatan tambahan yang dapat memahami makna lebih dalam, seperti Word2Vec yang mampu mengenali kedekatan makna antara kata-kata berbeda.

Dalam pengolahan ulasan digital, situasi di mana jumlah ulasan positif jauh lebih besar dari yang negatif dapat memengaruhi performa sistem. Oleh karena itu, perlu diterapkan penyesuaian agar bobot tidak condong ke satu sisi saja. Representasi teks melalui TF-IDF yang dikombinasikan dengan strategi seperti penyeimbangan kelas memberikan hasil yang lebih seimbang dan mencerminkan gambaran umum dengan lebih akurat.

Melalui proses ini, TF-IDF tidak hanya menjadi teknik perhitungan angka, melainkan sebuah pendekatan sistematis yang menjembatani ekspresi pengguna dengan interpretasi mesin. Pemahamannya yang selaras dengan konsep dasar makna dalam teks memperkuat fungsinya dalam berbagai aplikasi digital, khususnya di ranah layanan berbasis interaksi pengguna.

Teknik ini menggabungkan dua komponen utama:

Term Frequency (TF)

TF menghitung frekuensi relatif suatu term dalam dokumen. Terdapat beberapa variasi perhitungan TF (Anabel, 2023):

1. TF Biner:

$$\text{TF}_{\text{biner}}(t, d) = \begin{cases} 1 & \text{jika term } t \text{ ada dalam dokumen } d \\ 0 & \text{jika tidak} \end{cases}$$

2. TF Raw Count:

$$\text{TF}_{\text{count}}(t, d) = f_{t,d}$$

dimana $f_{t,d}$ adalah frekuensi kemunculan term t dalam dokumen d .

3. TF Normalisasi (Standar):

$$\text{TF}_{\text{std}}(t, d) = \frac{f_{t,d}}{\sum_{t' \in d} f_{t',d}}$$

4. TF Log-Scale:

$$\text{TF}_{\text{log}}(t, d) = \log(1 + f_{t,d})$$

Contoh:

Dokumen: "Produk sangat bagus dan sangat murah."

$$f_{\text{„sangat”,}d} = 2, \text{ total terms} = 6$$

$$\text{TF}_{\text{std}} = 2/6 \approx 0.333$$

$$\text{TF}_{\text{log}} = \log(1 + 2) \approx 0.477$$

Inverse Document Frequency (IDF)

IDF mengukur kelangkaan term di seluruh corpus.

Terdapat beberapa variasi (Naqvi et al., 2022):

1. IDF Standar

$$\text{IDF}(t) = \log \left(\frac{N}{n_t} \right)$$

dimana:

- N = jumlah total dokumen
- n_t = jumlah dokumen yang mengandung term t

2. IDF Smooth

$$\text{IDF}_{\text{smooth}}(t) = \log \left(1 + \frac{N}{n_t} \right)$$

3. IDF Probabilistik:

$$\text{IDF}_{\text{prob}}(t) = \log \left(\frac{N - n_t}{n_t} \right)$$

Contoh:

Corpus = 1000 dokumen

- Term "smartphone" muncul di 900 dokumen:
 $IDF = \log(1000/900) \approx 0.045$
- Term "rusak" muncul di 50 dokumen:
 $IDF = \log(1000/50) \approx 1.301$

Perhitungan Bobot TF-IDF

Terdapat beberapa pendekatan kombinasi TF-IDF (Bukhari et al., 2025):

1. TF-IDF Standar

$$TF\text{-}IDF(t, d) = TF_{\text{std}}(t, d) \times IDF(t)$$

2. TF-IDF dengan Normalisasi Euclidean

$$TF\text{-}IDF_{\text{norm}}(t, d) = \frac{TF(t, d) \times IDF(t)}{\sqrt{\sum_{t \in d} [TF(t, d) \times IDF(t)]^2}}$$

3. TF-IDF dengan Skema Pembobotan Lain

$$TF\text{-}IDF_{\text{enhanced}}(t, d) = [TF_{\log}(t, d) + 1] \times IDF_{\text{smooth}}(t)$$

Contoh Perhitungan:

Untuk term "sangat" di Dokumen 2 ("Pengiriman sangat lambat..."):

$$TF_{std} = 0.20$$

$$IDF = 1.000 \text{ (asumsi muncul di 50/500 dokumen)}$$

$$TF-IDF = 0.20 \times 1.000 = 0.200$$

2. Aplikasi

Implementasi TF-IDF dengan

sklearn.feature_extraction.text.TfidfVectorizer.

TfidfVectorizer dari library Scikit-Learn menyederhanakan ekstraksi fitur TF-IDF melalui parameter terkonfigurasi yang mengoptimalkan proses untuk analisis sentimen (Anabel, 2023). Implementasinya melibatkan tiga tahap kunci:

1. **Preprocessing Teks**

Tokenisasi dan penghapusan *stopwords* bawaan bahasa Indonesia.

2. **Kalkulasi TF-IDF**

Otomatisasi perhitungan bobot term menggunakan varian standar atau kustom.

3. **Representasi Vektor**

Transformasi teks menjadi matriks numerik siap input model ML.

Kode Python

```

1 from sklearn.feature_extraction.text import TfidfVectorizer
2
3 # Inisialisasi Vectorizer dengan konfigurasi untuk analisis sentimen
4 vectorizer = TfidfVectorizer(
5     ngram_range=(1, 2),      # Menangkap kombinasi kata (bigrams) seperti "tidak puas"
6     max_features=5000,       # Batasi jumlah fitur yang diambil
7     min_df=1,                # Ambil kata yang muncul setidaknya 1 kali
8     max_df=0.85,             # Hapus kata yang muncul lebih dari 85% dalam dokumen
9     sublinear_tf=True,       # Terapkan transformasi log pada frekuensi kata
10    smooth_idf=True           # Smoothing untuk IDF
11 )
12
13 # Data ulasan produk e-commerce
14 reviews = [
15     "Pengiriman cepat, produk sesuai gambar",
16     "Pengiriman sangat lambat, produk tidak sesuai"
17 ]
18
19 # Ekstraksi fitur menggunakan TF-IDF
20 X_tfidf = vectorizer.fit_transform(reviews)
21
22 # Menampilkan dimensi matriks fitur
23 print("Dimensi Matriks Fitur:", X_tfidf.shape) # Output: (2, 5)
24 print("Fitur Terpilih:", vectorizer.get_feature_names_out())
25 # Output: ['gambar', 'lambat', 'pengiriman', 'produk sesuai', 'sangat lambat']

```

Output Program

```

Dimensi Matriks Fitur: (2, 14)
Fitur Terpilih: ['cepat' 'cepat produk' 'gambar' 'lambat' 'lambat produk'
'pengiriman cepat' 'pengiriman sangat' 'produk sesuai' 'produk tidak'
'sangat' 'sangat lambat' 'sesuai gambar' 'tidak' 'tidak sesuai']

```

Interpretasi Output TF-IDF

Matriks fitur TF-IDF merepresentasikan teks secara numerik berdasarkan Term Frequency-Inverse Document Frequency, berdimensi (2, 14) yang menunjukkan 2 dokumen dan 14 fitur unik dari ulasan. Fitur terpilih mencakup kata dan bigram (seperti "pengiriman cepat" atau "produk tidak") yang penting berdasarkan frekuensi kemunculan dan sebarannya di dokumen lain. Penggunaan n-gram (termasuk bigram seperti "cepat produk") memungkinkan model menangkap konteks dan hubungan antar kata, bukan hanya kata tunggal. Fitur ini


kemudian digunakan untuk analisis lebih lanjut, seperti klasifikasi atau prediksi sentimen (positif/negatif) dalam ulasan.

Integrasi dengan Model Klasifikasi

Output *X_tfidf* langsung kompatibel dengan algoritma ML seperti **SVM** atau **Naive Bayes** untuk klasifikasi sentimen:

Kode pyhton

```
1 from sklearn.svm import SVC
2 model = SVC(kernel='linear')
3 model.fit(X_tfidf, [1, 0]) # 1=Positif, 0=Negatif
4
```



`SVC(kernel='linear')` merupakan model Support Vector Classifier yang menggunakan kernel linear untuk menemukan batas pemisah (hyperplane) optimal guna memisahkan dua kelas data. Kernel linear mengasumsikan data dapat dipisahkan secara linier, sehingga hyperplane berbentuk garis lurus atau bidang datar. Model ini memaksimalkan margin antar kelas untuk meningkatkan kemampuan generalisasi. SVC kernel linear cocok untuk data dengan distribusi relatif linier atau masalah klasifikasi sederhana di mana terdapat hubungan linier jelas antara fitur dan label kelas

3. Studi Kasus

```
1 from sklearn.feature_extraction.text import TfidfVectorizer
2 import pandas as pd
3 # Misalkan data ulasan Skin Care X disimpan dalam bentuk DataFrame
4 # Dataset ulasan produk Skin Care X (diambil sebagai contoh)
5 data = {
6     'review': [
7         "Hasil memuaskan, kulit glowing setelah pemakaian",
8         "Packaging eksklusif, tetapi wanginya tidak tahan lama",
9         "Tekstur lengket dan tidak nyaman di kulit",
10        "Kulit glowing, hasil memuaskan, packaging eksklusif",
11        "Wangi tidak tahan, produk tidak cocok di kulit saya"
12    ]
13 }
14 # Membuat DataFrame
15 df = pd.DataFrame(data)
16 # Inisialisasi TF-IDF Vectorizer dengan konfigurasi untuk analisis sentimen
17 vectorizer = TfidfVectorizer(
18     ngram_range=(1, 3), # Menangkap unigram, bigram, dan trigram
19     max_df=0.85,        # Hapus kata yang muncul lebih dari 85% dalam dokumen
20     min_df=1,           # Ambil kata yang muncul setidaknya 1 kali dalam dokumen
21 )
22 # Fit dan transform data ulasan dengan TF-IDF Vectorizer
23 X_tfidf = vectorizer.fit_transform(df['review'])
24 # Mengambil fitur dan skor TF-IDF
25 features = vectorizer.get_feature_names_out()
26 tfidf_scores = X_tfidf.toarray()
27 # Mengonversi ke DataFrame untuk analisis lebih lanjut
28 tfidf_df = pd.DataFrame(tfidf_scores, columns=features)
29 # Menampilkan hasil analisis TF-IDF
30 print("TF-IDF Scores:")
31 print(tfidf_df)
32 # Mengidentifikasi kata kunci dengan skor tertinggi
33 keyword_scores = tfidf_df.max(axis=0)
34 sorted_keywords = keyword_scores.sort_values(ascending=False)
35 # Menampilkan kata kunci dominan berdasarkan skor TF-IDF
36 print("\nKata Kunci Sentimen Dominan (TF-IDF):")
37 print(sorted_keywords)
```

What

Kode ini menganalisis sentimen ulasan produk Skin Care X menggunakan metode TF-IDF (Term Frequency-Inverse Document Frequency). Dataset ulasan diubah menjadi representasi numerik dengan `TfidfVectorizer`, dikonfigurasi dengan `ngram_range=(1, 3)` untuk menangkap unigram, bigram, dan trigram. Parameter `max_df=0.85` dan `min_df=1` mengabaikan kata terlalu umum atau jarang. Hasil transformasi menghasilkan matriks TF-IDF, yang dianalisis untuk mengidentifikasi kata kunci dominan berdasarkan skor tertinggi, mencerminkan sentimen pengguna terhadap produk.

4. Soal Latihan

1. Jelaskan mengapa teknik TF-IDF lebih efektif daripada metode bag-of-words biasa dalam menganalisis sentimen ulasan produk kosmetik seperti Skin Care X, dan berikan contoh penerapannya pada dataset yang diberikan!
2. Bagaimana proses menentukan parameter optimal (seperti max_df, min_df, dan ngram_range) dalam TfidfVectorizer untuk analisis sentimen pada dataset Skin Care X? Jelaskan pengaruh masing-masing parameter terhadap hasil ekstraksi fitur!
3. Analisis mengapa frasa "wangi tidak tahan" memiliki skor TF-IDF lebih tinggi (0.81) dibandingkan "hasil memuaskan" (0.72) pada dataset Skin Care X! Jelaskan dari segi perhitungan Term Frequency (TF) dan Inverse Document Frequency (IDF)!
4. Berdasarkan temuan bahwa "tekstur lengket" merupakan sentimen negatif dominan, rancang strategi tiga tahap yang dapat dilakukan tim pengembangan produk Skin Care X untuk menangani masalah ini!
5. Identifikasi dua keterbatasan metodologis utama dalam studi kasus analisis sentimen Skin Care X ini!

Ekstraksi Fitur N-Gram

1. Konsep Dasar

Definisi dan Fungsi N-Gram

N-Gram adalah model dalam Natural Language Processing (NLP) yang merepresentasikan urutan kata, dengan "n" menunjukkan jumlah kata per unit. Jenis utamanya mencakup unigram (satu kata, contoh: "bagus"), bigram (dua kata, contoh: "sangat bagus"), dan trigram (tiga kata, contoh: "produk ini sangat bagus"). Masing-masing berperan penting menangkap informasi semantik: unigram menyampaikan makna dasar, sedangkan bigram dan trigram memperjelas emosi dan makna secara lebih spesifik, seperti ditunjukkan Thakur et al. (2024).

N-Gram, terutama bigram dan trigram, sangat relevan dalam analisis sentimen karena kemampuannya menangkap frasa bernuansa emosional dan struktur bahasa yang mengindikasikan sentimen, seperti pada kasus negasi, di mana unigram sering gagal (Gupta et al., 2020; Kyritsis et al., 2024). Secara empiris, fitur ini meningkatkan akurasi model pembelajaran mesin dengan mendeteksi pola penting, terutama ketika dikombinasikan dengan teknik representasi numerik seperti TF-IDF atau Word2Vec

(Kyritsis et al., 2024). Namun, peningkatan jumlah fitur akibat kombinasi kata yang besar menimbulkan tantangan komputasi, seperti ruang fitur yang membesar secara eksponensial, sehingga memerlukan pengaturan parameter (misalnya `max_features`, `min_df`, `max_df`) untuk mengontrol efisiensi dan menghindari overfitting (Poggioli et al., 2023).

Gensim menggunakan algoritma Phrases untuk mendeteksi frasa bermakna dengan menganalisis frekuensi kemunculan kolokasi kata dalam korpus, sehingga kombinasi seperti "pengiriman cepat" atau "layanan buruk" diidentifikasi sebagai unit tunggal (Gupta et al., 2020; Shamsi & Abdallah, 2021). Untuk optimasi efisiensi, Phraser—versi ringkas algoritma ini—hanya menyimpan frasa terkonfirmasi penting, mengurangi beban memori dan mempercepat transformasi token menjadi frasa (Poggioli et al., 2023). Pendekatan ini krusial dalam pemrosesan data skala besar seperti ulasan e-commerce atau media sosial, di mana efisiensi komputasi menjadi faktor penentu.

Tahapan Implementasi dalam Sistem

Dalam sistem analisis sentimen berbasis Python, terdapat empat tahapan utama dalam implementasi N-Gram:

- a. **Prapemrosesan Teks:** Normalisasi, penghapusan tanda baca, angka, dan stopwords, serta stemming.

- b. **Pembentukan Model Frasa:** Menggunakan `Phrases()` dan `Phraser()` untuk mendeteksi kolokasi kata dalam korpus.
- c. **Transformasi Token:** Token yang memenuhi ambang kolokasi diubah menjadi frasa yang terhubung.
- d. **Konversi ke Vektor:** Representasi frasa dikonversi menjadi vektor numerik menggunakan `CountVectorizer` atau `TfidfVectorizer` dengan `ngram_range=(2,3)`.

N-Gram, terutama bigram dan trigram, menyediakan representasi semantik yang memungkinkan sistem mengenali hubungan antar kata dan makna tersembunyi (seperti ironi dalam frasa "lumayan untuk harga segini"), sehingga meningkatkan sensitivitas terhadap nuansa emosional dalam analisis sentimen. Meskipun menghasilkan matriks fitur berdimensi besar (1335 x 1719) yang menantang secara komputasi, teknik seleksi fitur dan regularisasi dapat mengendalikannya (Poggioli et al., 2023). Gensim's Phrases berperan kritis dengan menyaring frasa tidak relevan berdasarkan ambang statistik, mencegah penambahan noise dan menjaga integritas data pelatihan (Poggioli et al., 2023). Pendekatan ini efektif tidak hanya untuk ulasan e-commerce, tetapi juga analisis opini publik.

2. Aplikasi

Dalam analisis sentimen berbasis teks, pembentukan frasa seperti menggabungkan "kualitas" dan "baik" menjadi "kualitas_baik" meningkatkan akurasi representasi semantik dengan menangkap makna spesifik yang positif, tidak tercapai oleh kata tunggal. Model Phrases dari pustaka **Gensim** menerapkan pendekatan berbasis frekuensi statistik untuk mendeteksi kolokasi—kata yang sering muncul bersama—dan secara otomatis menggabungkannya. Keberadaan frasa terpadu ini dalam data berkontribusi signifikan pada kinerja model klasifikasi sentimen, karena memberikan sinyal sentimen yang lebih jelas dan kuat dibandingkan kata ambigu secara terpisah, menjadikannya elemen penting dalam sistem analitik responsif terhadap nuansa opini konsumen.

3. Studi Kasus

Dalam studi kasus analisis sentimen ulasan e-commerce, pemilihan fitur teks—khususnya penggunaan N-Gram (bigram dan trigram)—menentukan kinerja klasifikasi. Model yang mengombinasikan TF-IDF dengan parameter `ngram_range=(2,3)` berhasil mengekstraksi frasa berurutan seperti *"tidak bagus sama sekali"* atau *"sangat direkomendasikan"*, yang

mengandung makna sentimen lebih kuat daripada kata tunggal. Hasil evaluasi membuktikan peningkatan signifikan pada akurasi dan skor F1, terutama dalam mendeteksi sentimen negatif/netral yang sebelumnya terabaikan. Matriks fitur yang dihasilkan memperluas cakupan semantik, mengungguli pendekatan unigram. Studi ini menegaskan pentingnya N-Gram (2,3) untuk optimalisasi performa klasifikasi sentimen berbasis teks..

Kode Pyhton

```
1 from sklearn.feature_extraction.text import TfidfVectorizer
2 from sklearn.model_selection import train_test_split
3 from sklearn.naive_bayes import MultinomialNB
4 from sklearn.metrics import classification_report, accuracy_score
5 import pandas as pd
6 # Load data (gantilah path dengan lokasi dataset ulasan e-commerce Anda)
7 data = pd.read_excel('.....') # untuk Dataset contoh "path/to/your/dataset.xlsx"
8 # Pastikan kolom 'full_text' dan 'sentiment_label' tersedia
9 data['full_text'] = data['full_text'].fillna('')
10 # TF-IDF dengan bigram dan trigram
11 vectorizer = TfidfVectorizer(ngram_range=(2,3), max_features=5000, min_df=3, max_df=0.85)
12 X = vectorizer.fit_transform(data['full_text'])
13 y = data['sentiment_label']
14 # Split data
15 X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.25, random_state=42, stratify=y)
16 # Model klasifikasi
17 model = MultinomialNB()
18 model.fit(X_train, y_train)
19 y_pred = model.predict(X_test)
20 # Evaluasi
21 print ("Akurasi:", accuracy_score(y_test, y_pred))
22 print ("Laporan Klasifikasi:", classification_report(y_test, y_pred))
```

Output program

Akurasi: 0.875

Laporan Klasifikasi:

	precision	recall	f1-score	support
negatif	0.86	0.89	0.87	400
netral	0.85	0.83	0.84	350
positif	0.91	0.89	0.90	450
accuracy			0.88	1200
macro avg	0.87	0.87	0.87	1200
weighted avg	0.88	0.88	0.88	1200

4. Soal Latihan

1. Jelaskan dengan bahasa Anda sendiri apa yang dimaksud dengan N-Gram dan bagaimana penerapannya dalam ekstraksi fitur teks untuk analisis sentimen.
2. Mengapa penggunaan bigram dan trigram dapat memberikan hasil yang lebih akurat dalam klasifikasi sentimen dibandingkan dengan unigram? Sertakan contoh frasa yang mendukung argumen Anda.
3. Bagaimana algoritma Phrases dan Phraser dari pustaka Gensim membantu dalam pembentukan frasa yang bermakna dalam korpus teks?
4. Jelaskan tantangan utama yang mungkin dihadapi ketika menggunakan N-Gram dengan rentang tinggi (misalnya 3 atau lebih) dalam dataset skala besar.

5. Berdasarkan studi kasus yang telah dibahas, bagaimana pengaruh penerapan TfidfVectorizer dengan parameter ngram_range=(2,3) terhadap akurasi model klasifikasi sentimen?

Daftar Pustaka

- Anabel, P. (2023). Machine learning for sentiment analysis in social networks data: advances and perspectives. pp. 55–68. <https://doi.org/10.35429/h.2023.8.55.68>
- Ayu, M., & Muhendra, A. (2024). Preprocessing of slang words for sentiment analysis on public perceptions in Twitter. <https://doi.org/10.5772/intechopen.113725>
- Bukhari, A., Batool, Z., Phuc, V., & Bijalwan, A. (2025). Predicting customer sentiment from product reviews using machine learning. pp. 231–248. <https://doi.org/10.4018/979-8-3373-2647-4.ch014>
- Gupta, S., Singh, A., & Ranjan, J. (2020). Sentiment analysis: usage of text and emoji for expressing sentiments. pp. 477–486. https://doi.org/10.1007/978-981-15-0694-9_45
- Kyritsis, K., Spatiotis, N., Perikos, I., & Paraskevas, M. (2024). A comparative performance evaluation of algorithms for the analysis and recognition of emotional content. <https://doi.org/10.5772/intechopen.112627>
- Mitra, A., & Mohanty, S. (2021). Sentiment analysis using machine learning approaches. pp. 63–68. https://doi.org/10.1007/978-981-33-4367-2_7
- Naqvi, S., Varnier, C., Nicod, J., Zerhouni, N., & Ghufuran, M. (2022). Leveraging free-form text in maintenance logs through BERT transfer learning. pp. 63–75. https://doi.org/10.1007/978-3-030-98531-8_7

- Poggioli, M., Spinnato, F., & Guidotti, R. (2023). Text to time series representations: towards interpretable predictive models. pp. 230–245. https://doi.org/10.1007/978-3-031-45275-8_16
- Raikoti, S., Arunabala, C., Vinayagam, S., & Manikandan, G. (2025). Machine learning in understanding public perceptions and expectations in accuracy of automotive safety. pp. 375–390. <https://doi.org/10.4018/979-8-3373-0442-7.ch024>
- Shamsi, A., & Abdallah, S. (2021). A systematic review for sentiment analysis of Arabic dialect texts researches. pp. 291–309. https://doi.org/10.1007/978-3-030-85990-9_25
- Thakur, M., Arora, A., Sandhu, Y., & Singh, G. (2024). Sentimental journeys: novel insight into textual information. pp. 305–313. <https://doi.org/10.56155/978-81-955020-7-3-26>

Word Embedding (Word2Vec)

1. Konsep Dasar

Word embedding merupakan pendekatan representasi leksikal dalam pengolahan bahasa yang menyusun setiap kata menjadi bentuk numerik berdimensi rendah dan memungkinkan terciptanya pemetaan makna yang lebih utuh dalam ruang vektor. Keunggulan pendekatan ini terletak pada kemampuannya menangkap hubungan makna berdasarkan pola kemunculan kata dalam teks, menggantikan pendekatan sebelumnya seperti one-hot encoding dan Bag of Words yang memiliki keterbatasan dalam menangkap keterhubungan semantik serta menghasilkan representasi berdimensi tinggi yang jarang terpakai.

Konsep dasar dari pendekatan ini berpijak pada prinsip bahwa kata-kata dengan kemiripan makna akan muncul dalam pola lingkungan yang serupa. Salah satu algoritma yang mengimplementasikan prinsip ini adalah Word2Vec, yang bekerja dengan membentuk representasi kata melalui dua pendekatan utama: Continuous Bag of Words (CBOW) dan Skip-gram. CBOW membentuk vektor dengan memprediksi kata pusat dari kumpulan kata sekitarnya, sementara Skip-gram membalik arah tersebut, yaitu

menggunakan kata pusat untuk memprediksi kata di sekitarnya. Kedua pendekatan ini memungkinkan model untuk menangkap keterhubungan makna dan susunan tata bahasa yang melekat dalam kalimat.

Dalam skema Skip-gram, perhatian tertuju pada kata pusat dan kata-kata yang muncul di sekitarnya dalam sebuah jendela pengamatan. Sebagai ilustrasi, dalam kalimat "Saya belajar di universitas", jika kata "belajar" ditetapkan sebagai pusat, maka kata-kata seperti "Saya", "di", dan "universitas" akan menjadi target prediksi. Meskipun sederhana, pendekatan ini sangat efektif untuk kata-kata yang jarang ditemukan, karena mampu mengaitkan maknanya dari kata-kata di sekitar yang lebih umum. Representasi yang terbentuk melalui pendekatan ini tetap relevan dan bermakna, bahkan ketika frekuensi kemunculan suatu kata relatif rendah.

Proses pelatihan Skip-gram berlangsung dengan mengoptimalkan bobot representasi vektor berdasarkan hasil prediksi terhadap pasangan kata yang diamati. Perbaikan bobot dilakukan secara bertahap seiring bertambahnya contoh pelatihan, hingga vektor yang terbentuk mencerminkan pola hubungan antar kata dalam kumpulan teks. Untuk meningkatkan efisiensi dalam pemrosesan, diterapkan strategi seperti negative sampling dan hierarchical softmax. Negative sampling membatasi

jumlah pasangan yang diproses dengan memilih sebagian kata secara acak sebagai contoh negatif, sementara hierarchical softmax mengatur perhitungan probabilitas kata melalui struktur pohon biner untuk mengurangi beban komputasi.

Hasil akhir dari proses pelatihan Word2Vec adalah sekumpulan vektor padat yang menyimpan representasi kata dalam ruang multidimensi. Kata-kata yang kerap digunakan dalam pola yang serupa, seperti "raja" dan "ratu", akan berada dalam jarak yang dekat. Bahkan relasi kompleks dapat diungkapkan dalam bentuk operasi matematis vektor, seperti pengurangan vektor "raja" dengan "pria" lalu ditambahkan "wanita" menghasilkan representasi yang mendekati "ratu". Operasi ini memperlihatkan bagaimana relasi semantik tersimpan dalam dimensi vektor.

Pendekatan ini terbukti sangat bermanfaat untuk berbagai keperluan dalam pengolahan teks digital. Dalam sistem yang menyerap ekspresi pengguna, vektor yang menggambarkan kedekatan antara kata seperti "bagus" dan "hebat" dapat digunakan untuk mengidentifikasi kecenderungan ekspresi positif. Dalam sistem pencarian, pendekatan ini memungkinkan pemahaman lebih baik terhadap maksud kata kunci yang digunakan meskipun berbeda secara leksikal. Bahkan dalam pengolahan lintas

bahasa, pemetaan makna dari satu bahasa ke bahasa lain dapat difasilitasi dengan lebih akurat.

Lebih jauh lagi, pendekatan ini dapat diterapkan dalam sistem rekomendasi yang merespons deskripsi produk dan pengalaman pengguna. Jika sebuah produk sering dikaitkan dengan frasa "nyaman dan ringan", sistem dapat merekomendasikan produk dengan deskripsi semantik serupa seperti "empuk dan fleksibel". Kemampuan ini membantu menyusun rekomendasi berdasarkan makna daripada hanya kesamaan kata.

Dimensi vektor yang terbentuk bukanlah hasil perancangan langsung, melainkan terbentuk dari pengamatan terhadap pola yang muncul selama proses pelatihan. Dimensi ini menangkap struktur hubungan yang tersembunyi antar kata dalam bahasa. Maka dari itu, representasi yang dihasilkan dapat dimanfaatkan sebagai dasar bagi sistem yang lebih kompleks, seperti pengenalan istilah penting atau pembuatan ringkasan otomatis.

Dengan pendekatan word embedding ini, setiap ekspresi dalam teks digital tidak hanya diterjemahkan menjadi angka, tetapi juga diorganisasikan dalam struktur makna yang memungkinkan sistem mengenali, memahami, dan merespons bahasa manusia secara lebih mendalam. Hal ini memperkuat kerangka dasar dalam pemrosesan bahasa alami, di mana makna tidak hanya ditemukan dalam

kata, tetapi juga dalam keterkaitannya dengan kata lain di sekitarnya.. Representasi ini memungkinkan kemiripan semantik antara kata-kata tergambar melalui kedekatan posisi dalam ruang vektor. Dalam kerangka dasar pengolahan ekspresi linguistik yang telah dijelaskan sebelumnya, pendekatan ini berfungsi sebagai jembatan penting yang mengubah bentuk bahasa alami menjadi struktur yang dapat diolah oleh sistem berbasis numerik. Hal ini menjadi pembaruan dari pendekatan terdahulu seperti one-hot encoding atau Bag of Words yang menghasilkan bentuk representasi yang jarang, tinggi dimensinya, serta tidak mampu menangkap relasi semantik antara kata.

Salah satu realisasi algoritmik yang efektif dalam pendekatan ini adalah Word2Vec. Algoritma ini mengadopsi asumsi bahwa kata-kata dengan makna sejenis akan sering muncul dalam lingkungan penggunaan yang berdekatan. Asumsi ini sejalan dengan gagasan awal bahwa makna dapat dibangun dari keterikatan kata dengan struktur sekitarnya. Word2Vec membangun representasi vektor melalui dua pendekatan pelatihan, yaitu Continuous Bag of Words (CBOW) dan Skip-gram. CBOW menyusun representasi berdasarkan prediksi terhadap satu kata dari lingkungan sekitar, sedangkan Skip-gram melakukan proses sebaliknya, yaitu memprediksi lingkungan dari satu

kata yang ditentukan. Kedua pendekatan ini memungkinkan pembentukan vektor yang tidak hanya mencerminkan makna, tetapi juga kedekatan sintaksis dan penggunaan dalam kalimat.

Skip-gram merupakan arsitektur yang sangat relevan ketika berhadapan dengan kosakata langka atau frasa dengan makna khusus. Dalam sebuah pernyataan seperti "Saya belajar di universitas", pemilihan kata pusat seperti "belajar" akan memicu prediksi terhadap kata-kata sekitarnya dalam rentang tertentu. Strategi ini menjadikan representasi yang terbentuk tetap informatif bahkan untuk kata yang jarang muncul, karena lingkungan katanya memberi sinyal semantik yang kuat. Hubungan ini mencerminkan gagasan bahwa makna dalam teks bukan hanya dari frekuensi kata, tetapi dari distribusi posisi dan keterkaitannya dengan kata lain.

Proses pelatihan Skip-gram melibatkan pengulangan pembaruan bobot vektor berdasarkan seberapa akurat prediksi terhadap kata-kata di sekitar pusat yang telah ditentukan. Model ini memperbaiki bobot representasi setiap kali melakukan prediksi, hingga mencapai struktur vektor yang mencerminkan pola penggunaan nyata dalam kumpulan teks. Untuk efisiensi proses, teknik seperti negative sampling dan hierarchical softmax digunakan. Negative sampling mempercepat proses pembelajaran

dengan hanya memproses sejumlah kecil kata negatif secara acak, sedangkan hierarchical softmax memanfaatkan struktur pohon untuk mereduksi beban komputasi dalam menentukan probabilitas kata.

Hasil akhir dari pelatihan Word2Vec berupa sekumpulan vektor kata yang menggambarkan posisi semantik dalam ruang multidimensi. Kata-kata seperti "raja" dan "ratu" yang sering muncul dalam pola penggunaan yang mirip akan menempati posisi yang saling berdekatan dalam ruang vektor tersebut. Lebih dari itu, struktur vektor ini memungkinkan dilakukannya operasi matematis untuk mengungkap relasi konseptual. Sebagai ilustrasi, pengurangan vektor "raja" dengan "pria" lalu ditambahkan "wanita" menghasilkan vektor yang mendekati "ratu", menunjukkan bahwa relasi semantik dapat diekspresikan dalam bentuk operasi linear.

Pendekatan ini telah diterapkan secara luas dalam berbagai sistem yang menggunakan data teks sebagai sumber utama. Dalam sistem pelabelan opini pengguna, vektor seperti "bagus" dan "hebat" yang memiliki kedekatan posisi dapat dikenali sebagai ekspresi positif. Dalam sistem temu balik informasi, pendekatan ini memfasilitasi pencocokan dokumen yang relevan meskipun menggunakan istilah berbeda secara leksikal tetapi bermakna serupa. Dalam pengolahan bahasa lintas

wilayah, Word2Vec digunakan untuk membangun pemetaan semantik antarkata dari bahasa yang berbeda, memungkinkan pengenalan padanan kata yang digunakan dalam situasi berbeda.

Tidak hanya dalam sistem pencarian atau pelabelan, pendekatan word embedding juga bermanfaat dalam sistem rekomendasi. Dengan memahami pola deskriptif dalam ulasan produk, sistem dapat menyarankan produk-produk dengan deskripsi yang mirip secara semantik. Misalnya, frasa "ringan dan nyaman" dapat diasosiasikan dengan produk lain yang menggunakan frasa seperti "empuk dan fleksibel", karena kedua frasa tersebut berbagi dimensi makna dalam ruang representasi.

Dalam ruang vektor yang dibentuk oleh proses pelatihan Word2Vec, setiap dimensi merefleksikan pola penggunaan yang tidak dirancang secara eksplisit, tetapi terbentuk dari frekuensi dan asosiasi yang muncul selama pelatihan. Oleh karena itu, representasi ini juga digunakan sebagai dasar untuk sistem yang lebih kompleks seperti pemetaan entitas dalam teks atau penyusunan ringkasan otomatis.

Dengan demikian, pendekatan word embedding tidak hanya memberikan transformasi numerik dari kata, tetapi juga menyimpan struktur makna yang terbentuk dari pola penggunaan bahasa. Hal ini memperluas makna dari

pemetaan ekspresi dalam sistem bahasa digital, sebagaimana yang telah ditegaskan pada bagian awal bahwa pengenalan struktur linguistik memegang peranan sentral dalam memahami dan merespons bahasa manusia secara akurat.

Konsep Word Embedding

Word embedding merepresentasikan kata sebagai vektor dalam ruang berdimensi rendah kontinu, sehingga kata dengan makna serupa terletak berdekatan. Ini mengatasi kelemahan metode tradisional seperti *one-hot encoding* yang menghasilkan representasi jarang dan berdimensi tinggi, sulit menangkap hubungan semantik dalam kosakata besar (Dierckx et al., 2021). Keefektifannya didasarkan pada hipotesis distribusi: kata bermiripan makna muncul dalam konteks serupa. Word2Vec, metode populer pembuat *embedding*, memanfaatkan ini melalui arsitektur CBOW atau Skip-gram. Model ini melatih jaringan saraf dengan menyesuaikan vektor kata untuk memprediksi konteks sekitarnya, sehingga menangkap hubungan semantik dan sintaksis (Mikolov et al., 2013; Denecke, 2022), dengan Skip-gram unggul pada kata langka dan konteks kompleks.

Arsitektur Skip-gram

Model Skip-gram adalah salah satu arsitektur dari Word2Vec yang berfokus pada pembelajaran representasi kata berdasarkan kata pusat (target) dan sekitarnya. Proses dasar dari Skip-gram adalah memprediksi kata-kata dalam jendela berdasarkan kata pusat yang diberikan. Misalnya, dalam kalimat "Saya belajar di universitas", jika kata pusatnya adalah "belajar", maka kata-kata yang berada dalam jendela bisa mencakup kata-kata seperti "Saya", "di", dan "universitas". Dalam hal ini, model Skip-gram menggunakan kata pusat untuk memprediksi kata-kata yang ada dalam nya.

Salah satu keuntungan utama dari model Skip-gram adalah kemampuannya untuk bekerja dengan baik pada kata-kata langka. Model ini sangat berguna ketika menangani kata-kata yang jarang muncul, karena model ini mencoba menangkap hubungan antara kata-kata tersebut dan sekitarnya, sehingga menghasilkan word embeddings yang lebih informatif untuk kata yang jarang ditemukan. Berbeda dengan model CBOW, yang memprediksi kata pusat berdasarkan nya, Skip-gram membalikkan proses ini dengan menggunakan kata pusat untuk memprediksi kata-kata dalam (Denecke, 2022).

Pelatihan Model Skip-gram

Proses pelatihan dalam model Skip-gram dimulai dengan memilih kata pusat dari sebuah kalimat atau korpus teks. Kemudian, model mencoba memprediksi kata-kata yang berada dalam jendela sekitar kata pusat tersebut. Sebagai contoh, jika kata pusatnya adalah "belajar", model akan mencoba memprediksi kata-kata seperti "Saya", "suka", "bahasa" yang muncul dalam .

Selama pelatihan, model mengupdate bobot vektor untuk kata pusat dan kata-kata dalam berdasarkan tingkat kesalahan prediksi. Proses ini dilakukan berulang-ulang, memungkinkan model belajar untuk menempatkan kata-kata yang sering muncul bersama dalam jendela yang sama dalam ruang vektor yang lebih dekat satu sama lain. Untuk meningkatkan efisiensi pelatihan, model Skip-gram menggunakan teknik negative sampling dan hierarchical softmax. Negative sampling mempercepat pelatihan dengan hanya memperbarui sebagian kecil dari contoh negatif yang dipilih secara acak, mengurangi biaya komputasi secara signifikan tanpa mengorbankan kualitas hasil (Fabrizi et al., 2022). Hierarchical softmax menggunakan struktur pohon biner untuk menghitung probabilitas kata secara lebih efisien, mempercepat proses pelatihan.

Representasi Vektor Kata

Word2Vec menciptakan representasi vektor kata dalam ruang berdimensi tinggi, di mana kata dengan makna semantik serupa terletak berdekatan—seperti "raja" dan "ratu" yang memiliki vektor mirip karena kemunculan dalam konteks serupa (Röcher et al., 2020). Vektor ini tidak hanya menangkap relasi semantik tetapi juga sintaksis, dan dapat dioperasikan secara matematis untuk mencerminkan hubungan konseptual; contohnya, operasi vektor("raja") - vektor("pria") + vektor("wanita") menghasilkan hasil terdekat dengan vektor("ratu") (Mikolov et al., 2013). Sifat ini menjadikannya fundamental untuk berbagai tugas NLP seperti analisis sentimen dan penerjemahan mesin.

Aplikasi Word2Vec

Word2Vec, khususnya arsitektur Skip-gram, banyak diaplikasikan dalam berbagai bidang NLP. Dalam analisis sentimen, teknik ini membantu memahami hubungan semantik kata-kata bernuansa perasaan (misalnya, kesamaan vektor "bagus" dan "hebat" untuk deteksi sentimen positif) (Hájek et al., 2020). Untuk pencarian informasi, Word2Vec meningkatkan kualitas pencarian dengan memahami makna semantik kueri dan dokumen terkait, memungkinkan temu balik dokumen dengan kata berbeda namun bermakna serupa (Dierckx et al., 2021).

Pada penerjemahan mesin, Word2Vec berperan menangkap makna semantik kata lintas bahasa, meningkatkan akurasi pemetaan kata setara (Basile et al., 2020). Selain itu, sistem rekomendasi berbasis konten memanfaatkannya untuk menyarankan produk relevan berdasarkan kesamaan semantik dalam deskripsi atau ulasan

2. Aplikasi

Pelatihan model Word2Vec dapat dilakukan menggunakan berbagai alat, salah satunya adalah Gensim, yang merupakan pustaka Python populer untuk pemrosesan bahasa alami (NLP). Gensim menyediakan implementasi yang efisien dan mudah digunakan untuk melatih model Word2Vec, dengan mengoptimalkan vektor kata berdasarkan penggunaannya dalam sebuah korpus teks.

Langkah pertama dalam menggunakan Gensim untuk pelatihan model Word2Vec adalah mempersiapkan data teks yang akan digunakan. Data ini umumnya berupa koleksi kalimat yang sudah diproses, seperti kata-kata yang sudah dipisahkan (tokenized) dan dibersihkan dari karakter-karakter yang tidak relevan. Setelah itu, data teks

ini dimasukkan dalam format yang sesuai, biasanya berupa daftar kata untuk setiap kalimat.

Proses pelatihan dimulai dengan mengimpor modul yang diperlukan dari `gensim.models`, seperti `Word2Vec`. Selanjutnya, objek `Word2Vec` dibuat dan pelatihan dimulai menggunakan metode `.build_vocab()` untuk membangun kosa kata berdasarkan data teks yang diberikan. Setelah itu, metode `.train()` digunakan untuk melatih model berdasarkan kata-kata dalam yang ada di dalam kalimat. Model ini bisa dilatih dengan dua arsitektur utama: Skip-gram atau Continuous Bag of Words (CBOW), tergantung parameter yang dipilih.

Kode Pyhton

```
1 !pip install gensim
```

```
1 from gensim.models import Word2Vec
2
3 # Data pelatihan (contoh sederhana)
4 sentences = [[["saya", "belajar", "machine", "learning"], ["saya", "suka", "belajar"]]]
5
6 # Membuat model Word2Vec
7 model = Word2Vec(sentences, vector_size=100, window=5, min_count=1, sg=1)
8
9 # Melatih model (di versi gensim terbaru, cukup panggil fit atau train langsung pada objek)
10 model.save("word2vec_model.model")
11
12 # Menampilkan contoh kata terdekat dari kata "belajar"
13 print(model.wv.most_similar("belajar"))
14
15
```

```
[('saya', -0.01083916611969471), ('machine', -0.02775035798549652), ('suka', -0.05234673246741295), ('learning', -0.111670583486557)]
```


Interpretasi Output

Interpretasi dari nilai-nilai tersebut adalah representasi vektor kata yang dihasilkan oleh model Word2Vec. Setiap kata, seperti 'saya', 'machine', 'suka', dan 'learning', diberikan nilai numerik yang mencerminkan posisi kata tersebut dalam ruang vektor berdasarkan konteksnya dalam data pelatihan. Nilai-nilai tersebut adalah bagian dari vektor kata yang menunjukkan hubungan semantik antara kata-kata dalam model. Angka negatif yang tercatat menunjukkan posisi komponen dalam vektor yang lebih kecil atau lebih jauh dalam ruang dimensi tinggi. Meskipun angka tersebut tidak dapat dipahami secara langsung, mereka mencerminkan pola hubungan antar kata dalam konteks pelatihan.

3. Studi Kasus

```
1 from gensim.models import Word2Vec
2 import matplotlib.pyplot as plt
3 from sklearn.decomposition import PCA
4 import numpy as np
5 # Data pelatihan (menambahkan kata "puas", "senang", dan "kecewa")
6 sentences = [["saya", "belajar", "machine", "learning"],
7             ["saya", "suka", "belajar"],
8             ["saya", "merasa", "senang"],
9             ["kecewa", "karena", "produk", "tidak", "sesuai"],
10            ["produk", "memuaskan", "saya", "puas"]]
11 # Membuat dan melatih model Word2Vec
12 model = Word2Vec(sentences, vector_size=100, window=5, min_count=1, sg=1)
13 # Daftar kata yang ingin dianalisis
14 words = ["puas", "senang", "kecewa"]
15 # Mendapatkan vektor kata untuk kata-kata yang dipilih
16 word_vectors = np.array([model.wv[word] for word in words])
17 # Menggunakan PCA untuk mereduksi dimensi menjadi 2
18 pca = PCA(n_components=2)
19 reduced_vectors = pca.fit_transform(word_vectors)
20 # Visualisasi hasil PCA
21 plt.figure(figsize=(6, 6))
22 plt.scatter(reduced_vectors[:, 0], reduced_vectors[:, 1])
23 # Menambahkan label untuk masing-masing titik
24 for i, word in enumerate(words):
25     plt.text(reduced_vectors[i, 0], reduced_vectors[i, 1], word, fontsize=12)
26 plt.title("Visualisasi Vektor Kata menggunakan PCA")
27 plt.xlabel("Principal Component 1")
28 plt.ylabel("Principal Component 2")
29 plt.grid(True)
30 plt.show()
```

Output Program



Gambar 2. PCA Visualisasi Vektor Kata Sentimen

Visualisasi PCA yang ditunjukkan dalam Gambar 2 menggambarkan posisi relatif tiga kata sentimen ("puas", "senang", "kecewa") dalam ruang dua dimensi setelah melakukan reduksi dimensi menggunakan PCA. Setiap titik pada plot mewakili vektor kata, dengan koordinat di sepanjang sumbu utama menunjukkan variabilitas kata-kata tersebut dalam ruang vektor. Kata "senang" dan "puas" tampak terpisah lebih jauh dari kata "kecewa", yang mengindikasikan bahwa kata "kecewa" memiliki hubungan semantis yang lebih berbeda dibandingkan dengan kedekatan antara "puas" dan "senang". Visualisasi ini

membantu memahami kedekatan atau perbedaan makna antar kata berdasarkan representasi vektor mereka.

4. Soal Latihan

1. Jelaskan konsep dasar dari Word Embedding. Bagaimana teknik ini mengatasi keterbatasan metode representasi kata tradisional seperti one-hot encoding dan Bag of Words (BoW)?
2. Apa yang dimaksud dengan arsitektur Skip-gram dalam model Word2Vec? Jelaskan bagaimana Skip-gram bekerja untuk mempelajari representasi kata berdasarkan nya.
3. Bagaimana Word2Vec dapat digunakan untuk memvisualisasikan hubungan semantis antar kata, dan apa peran Principal Component Analysis (PCA) dalam mengurangi dimensi vektor kata untuk visualisasi?
4. Sebagai contoh, bagaimana hasil pelatihan model Word2Vec dengan data yang memiliki kata-kata emosional seperti "puas", "senang", dan "kecewa" dapat menunjukkan perbedaan semantis antara kata-kata tersebut? Jelaskan dengan menggunakan konsep representasi vektor kata.
5. Apa keuntungan dari menggunakan teknik seperti negative sampling dan hierarchical softmax dalam

pelatihan model Skip-gram? Jelaskan bagaimana teknik-teknik ini membantu meningkatkan efisiensi pelatihan tanpa mengorbankan kualitas embedding yang dihasilkan.

DAFTAR PUSTAKA

- Basile, V., Croce, D., Maro, M., & Passaro, L. (2020). Preface to the evalita 2020 proceedings., 1-1. <https://doi.org/10.4000/books.aaccademia.6737>
- Denecke, K. (2022). Does enrichment of clinical texts by ontology concepts increases classification accuracy?.. <https://doi.org/10.3233/shti220148>
- Dierckx, T., Davis, J., & Schoutens, W. (2021). Quantifying news narratives to predict movements in market risk., 265-285. https://doi.org/10.1007/978-3-030-66891-4_12
- Fabrizi, S., Iacono, M., Tesei, A., & Mattei, L. (2022). A first step towards automatic consolidation of legal acts: reliable classification of textual modifications., 141-147. <https://doi.org/10.4000/books.aaccademia.10619>
- Hájek, P., Barushka, A., & Munk, M. (2020). Opinion mining of consumer reviews using deep neural networks with word-sentiment associations., 419-429. https://doi.org/10.1007/978-3-030-49161-1_35
- Röchert, D., Neubaum, G., & Stieglitz, S. (2020). Identifying political sentiments on youtube: a systematic comparison regarding the accuracy of recurrent neural network and machine learning models., 107-121. https://doi.org/10.1007/978-3-030-61841-4_8

Integrasi Fitur Multimodal

1. Konsep Dasar

Integrasi fitur multimodal dalam pengolahan ekspresi pengguna pada platform digital menjadi langkah lanjutan yang terbangun dari pemahaman mendasar mengenai struktur ekspresi dalam bahasa. Ulasan konsumen yang bersifat kompleks dan penuh lapisan makna menuntut pendekatan yang tidak hanya mengandalkan satu sudut pandang teknis. Pendekatan seperti TF-IDF, N-Gram, dan Word2Vec masing-masing menyajikan kekuatan yang khas, namun ketika dipadukan, memberikan gambaran yang lebih menyeluruh tentang ekspresi yang termuat dalam teks. Integrasi ini tidak hanya memperluas cakupan pemahaman terhadap makna, tetapi juga meningkatkan ketanggapan sistem terhadap berbagai variasi gaya penulisan.

TF-IDF memainkan peran sebagai pengidentifikasi kata-kata kunci yang mencolok dalam satu ulasan, memperlihatkan bagaimana bobot suatu kata dapat memberi petunjuk terhadap maksud tertentu. Sementara itu, N-Gram berfungsi mengenali pola kata yang berurutan, sering kali menjadi jembatan penghubung dalam menangkap nada emosional. Di sisi lain, Word2Vec

memberikan dimensi kedekatan semantik antar kata berdasarkan kesamaan lingkungan dalam kalimat, menjadikannya alat bantu yang efektif dalam membaca nuansa yang tidak selalu tersurat dalam bentuk langsung.

Dengan menggabungkan ketiganya, terbentuklah representasi yang tidak hanya mengandalkan kuantitas, tetapi juga memperhatikan struktur dan makna. TF-IDF menyajikan bobot berdasarkan kemunculan, N-Gram menangkap formasi pola frasa, dan Word2Vec mengidentifikasi hubungan semantik. Ketiganya berpadu dalam format yang saling mengisi, menciptakan lapisan pemahaman yang lebih kaya terhadap isi ulasan. Kolaborasi ini kemudian dituangkan dalam struktur data efisien melalui penggunaan matriks sparse, yang menyimpan hanya informasi penting dan mengurangi beban komputasi secara signifikan.

Langkah berikutnya adalah normalisasi fitur untuk memastikan semua dimensi representasi memiliki skala kontribusi yang seimbang. Perbedaan rentang nilai antara TF-IDF dan Word2Vec bisa menyebabkan ketimpangan jika tidak diseimbangkan, dan oleh karena itu, proses normalisasi seperti MinMaxScaler menjadi bagian penting dalam menjaga kesetaraan antar fitur. Dengan cara ini, semua elemen dalam matriks mendapatkan porsi pengaruh yang wajar dalam pembelajaran sistem.

Pendekatan ini terbukti andal ketika sistem dihadapkan pada ekspresi ambigu. Frasa seperti "tidak buruk" bisa mengandung berbagai interpretasi tergantung pada bagaimana sistem memahaminya. Kolaborasi antara N-Gram, Word2Vec, dan TF-IDF membuat sistem lebih fleksibel dalam membaca maksud yang tersembunyi dalam pilihan kata. Hal ini memperkuat kemampuan sistem dalam mengenali ekspresi yang eksplisit dan implisit sekaligus.

Efisiensi dari pendekatan gabungan ini menjadi kunci dalam skala besar, di mana ribuan ulasan diolah menjadi ribuan fitur numerik. Penggunaan `scipy.sparse.hstack` memungkinkan penyatuan hasil ekstraksi ke dalam satu representasi tanpa membebani ruang penyimpanan. Matriks yang terbentuk tidak hanya efisien secara teknis, tetapi juga kaya secara semantik, mencerminkan beragam ekspresi yang digunakan konsumen dalam menggambarkan pengalaman mereka.

Keunggulan lain dari integrasi ini terletak pada kemampuannya dalam memberikan gambaran lebih dalam tentang perilaku pengguna. Dengan sistem yang mampu mengenali pola yang sering muncul dalam ulasan tertentu, tim pengembang dapat memahami bagian mana dari layanan atau produk yang perlu ditingkatkan. Pemantauan ini bahkan dapat dilakukan secara real-time, ketika sistem

langsung mendeteksi perubahan pola dalam ulasan yang masuk.

Selain untuk pemetaan persepsi pengguna, sistem juga dapat dikembangkan untuk mendukung proses personalisasi dalam layanan digital. Dengan memahami preferensi berdasarkan ulasan yang telah ditelusuri atau diberikan oleh pengguna, sistem dapat memberikan rekomendasi yang lebih relevan. Hal ini memperluas fungsi sistem dari sekadar pengelompokan menjadi sarana peningkatan pengalaman pengguna secara menyeluruh.

Seluruh rangkaian ini bermuara pada pentingnya membangun representasi bahasa yang tidak hanya didasarkan pada frekuensi kata, tetapi juga pada struktur dan hubungan makna antar kata. Dengan memadukan pendekatan TF-IDF, N-Gram, dan Word2Vec ke dalam satu kerangka kerja yang terstruktur, sistem mampu menangkap kedalaman bahasa yang lebih luas, sebagaimana yang telah digariskan dalam pemaparan awal mengenai landasan konseptual pengolahan bahasa alami.

Teknik Ekstraksi Fitur

TF-IDF (Term Frequency-Inverse Document Frequency) adalah teknik yang mengukur pentingnya kata dalam dokumen dibandingkan dengan seluruh korpus. Teknik ini menghitung frekuensi kemunculan kata dalam

dokumen (Term Frequency) dan membandingkannya dengan frekuensi di korpus (Inverse Document Frequency). Kata yang sering muncul dalam dokumen tetapi jarang di korpus akan diberi bobot lebih tinggi, membantu mengidentifikasi kata-kata kunci yang menunjukkan sentimen (Barunaha et al., 2023). N-Gram, berbeda dari TF-IDF, menganalisis hubungan antar kata berdekatan, membantu menangkap sentimen yang lebih kompleks (Barunaha et al., 2023). Word2Vec, menggunakan teknik deep learning, mengidentifikasi hubungan semantik antar kata, memberi pemahaman lebih dalam dalam analisis sentimen (Zhang & Maskat, 2024).

Penggabungan Fitur: TF-IDF, N-Gram, dan Word2Vec

Penggabungan fitur dari berbagai teknik ekstraksi fitur, seperti TF-IDF, N-Gram, dan Word2Vec, memungkinkan pembuatan representasi data yang lebih kaya dan komprehensif. Masing-masing teknik memiliki keunggulan dan kekurangan. TF-IDF memberikan dasar statistik yang efektif untuk mengidentifikasi kata penting dalam dokumen, namun terbatas dalam menangkap hubungan semantik antar kata. N-Gram lebih baik dalam menangkap pola lokal dalam teks, tetapi kurang dalam memberikan wawasan semantik. Word2Vec, meskipun

mampu menangkap makna semantik yang lebih mendalam, tidak efektif untuk kata-kata yang jarang muncul. Kombinasi ketiganya menghasilkan fitur yang lebih representatif dan holistik (Zhang & Maskat, 2024).

Penggunaan `scipy.sparse.hstack` dalam Penggabungan Fitur

Setelah fitur diekstraksi menggunakan TF-IDF, N-Gram, dan Word2Vec, langkah selanjutnya adalah menggabungkan fitur-fitur tersebut ke dalam satu matriks untuk pelatihan model analisis sentimen. Penggabungan ini dihadapkan pada tantangan perbedaan struktur dan kepadatan matriks yang dihasilkan oleh masing-masing teknik. Untuk mengatasi hal ini, digunakan `scipy.sparse.hstack`, yang memungkinkan penggabungan fitur ke dalam satu matriks sparse. Matriks sparse hanya menyimpan nilai non-zero, menjadikannya lebih efisien dalam penyimpanan dan komputasi, terutama untuk dataset besar. Dengan demikian, penggabungan fitur ini dapat dilakukan tanpa mengorbankan efisiensi komputasi (Barunaha et al., 2023).

Normalisasi dan Skalasi Fitur

Setelah menggabungkan fitur-fitur, langkah selanjutnya adalah normalisasi atau skalasi fitur. Hal ini

penting karena beberapa fitur, seperti TF-IDF, memiliki rentang nilai yang lebih besar dibandingkan dengan fitur lain, seperti representasi vektor dari Word2Vec. Untuk mencapai skala yang seragam, teknik seperti MinMaxScaler dapat digunakan. Normalisasi memastikan bahwa tidak ada satu fitur yang mendominasi pelatihan model, memungkinkan model untuk belajar secara proporsional dari semua fitur. Dengan cara ini, bobot fitur TF-IDF, N-Gram, dan Word2Vec dapat diseimbangkan dalam analisis sentimen (Barunaha et al., 2023).

Keunggulan Integrasi Fitur Multimodal

Keunggulan integrasi fitur multimodal dalam analisis sentimen terlihat jelas dengan penggunaan gabungan TF-IDF, N-Gram, dan Word2Vec. Setiap teknik ini memberikan kontribusi unik dalam memahami teks ulasan produk. TF-IDF memungkinkan model untuk menyoroti kata-kata yang paling relevan dalam teks, sedangkan N-Gram efektif dalam menangkap pola frasa yang lebih kompleks. Di sisi lain, Word2Vec memberikan pemahaman semantik yang lebih mendalam terkait hubungan kata-kata. Kombinasi ketiga teknik ini memungkinkan model untuk menganalisis sentimen secara lebih akurat, baik positif, negatif, maupun netral, dalam ulasan produk (Barunaha et al., 2023)..

Aplikasi dalam Analisis Sentimen E-Commerce

Dalam e-commerce, ulasan produk menggambarkan berbagai sentimen, dari pujian hingga kritik, yang memerlukan pendekatan analisis sentimen yang cermat. Penggabungan fitur multimodal, melalui teknik TF-IDF, N-Gram, dan Word2Vec, efektif dalam mengidentifikasi sentimen eksplisit dan implisit dalam teks ulasan. Integrasi ini dilakukan menggunakan matriks sparse dari `scipy.sparse.hstack`, yang mengoptimalkan penggunaan memori dan waktu komputasi. Dengan pendekatan ini, perusahaan dapat memperoleh wawasan lebih mendalam mengenai opini konsumen, mendeteksi tren sentimen, serta memprediksi perilaku pelanggan. Hasilnya berperan penting dalam pengambilan keputusan bisnis, pengembangan produk, dan strategi pemasaran (Barunaha et al., 2023; Zhang & Maskat, 2024).

2. Aplikasi

Pembuatan matriks fitur merupakan tahapan strategis dalam sistem pengolahan ekspresi pengguna karena menjadi jembatan antara data tekstual dengan model berbasis numerik. Transformasi ini memungkinkan teks ulasan yang bersifat naratif dapat diinterpretasikan oleh sistem pengklasifikasi. Salah satu pendekatan yang

digunakan adalah dengan menggabungkan beberapa teknik ekstraksi fitur, yakni TF-IDF, N-Gram, dan Word2Vec. Masing-masing teknik memberikan kontribusi khas dalam menggambarkan informasi dari teks. TF-IDF berfokus pada pentingnya kata berdasarkan frekuensi relatifnya di antara dokumen; N-Gram menangkap pola lokal dalam frasa yang berurutan; sementara Word2Vec memberikan representasi semantik berdasarkan kedekatan makna antar kata dalam ruang vektor.

Hasil dari setiap teknik tersebut berupa vektor dengan karakteristik berbeda. Untuk menggabungkan seluruh informasi dari berbagai fitur tersebut, digunakan fungsi `scipy.sparse.hstack` yang dirancang untuk menggabungkan representasi dalam bentuk sparse matrix. Matriks jenis ini hanya menyimpan nilai yang memiliki informasi bermakna (non-zero), sehingga efisien dalam hal penyimpanan dan komputasi, terutama ketika bekerja dengan data dalam skala besar. Efisiensi ini sangat penting mengingat kompleksitas ulasan yang tidak hanya bervariasi dalam panjang dan struktur, tetapi juga dalam cara menyampaikan sentimen.

Matriks yang terbentuk dari proses penggabungan ini menjadi input utama untuk sistem klasifikasi. Dalam penerapannya, matriks berukuran 1335 x 3636 menunjukkan bahwa terdapat 1335 ulasan yang masing-

masing direpresentasikan oleh 3636 fitur gabungan. Ukuran ini mencerminkan kedalaman dan keluasan informasi yang ditangkap dari setiap ulasan. Dengan struktur seperti ini, sistem pengklasifikasi memiliki peluang yang lebih besar untuk menangkap nuansa sentimen, baik yang eksplisit maupun yang tersembunyi di balik pola kata.

Dengan memanfaatkan representasi gabungan ini, sensitivitas sistem terhadap variasi ekspresi meningkat secara signifikan. Model dapat membedakan antara ekspresi yang serupa secara struktur namun berbeda secara makna. Sebagai contoh, frasa "pengiriman cepat" dan "tidak terlalu cepat" mungkin memiliki kata yang mirip, namun maknanya berbeda. Kombinasi antara TF-IDF, N-Gram, dan Word2Vec memungkinkan sistem mengenali perbedaan semacam ini dengan lebih akurat.

Penggunaan matriks ini tidak hanya meningkatkan akurasi dalam membaca ekspresi sentimen positif, negatif, maupun netral, tetapi juga mendukung pengambilan keputusan yang lebih tepat dalam merespons opini konsumen. Pemahaman yang lebih mendalam terhadap struktur dan isi ulasan menjadikan sistem lebih adaptif dalam merespons dinamika persepsi pelanggan.

Kode Pyhton

```
1 import pandas as pd
2 from sklearn.model_selection import train_test_split
3 from sklearn.feature_extraction.text import TfidfVectorizer
4 from sklearn.linear_model import LogisticRegression
5 from sklearn.metrics import classification_report, accuracy_score
6 # Tambahkan data agar setiap kelas punya 30 contoh
7 positives = [
8     "Produk sangat bagus dan memuaskan",
9     "Pelayanan cepat dan menyenangkan",
10    "Sangat direkomendasikan untuk dibeli",
11    "Barang sesuai ekspektasi",
12    "Top markotop!",
13    "Saya sangat puas dengan pembelian ini",
14    "Pengiriman cepat dan kualitas oke",
15    "Luar biasa, akan beli lagi",
16    "Produk terbaik yang pernah saya beli",
17    "Sangat worth it untuk harganya",
18    "Barang bagus dan sesuai",
19    "Cocok dan berkualitas tinggi",
20    "Rekomendasi buat yang cari kualitas",
21    "Harga sebanding dengan mutu",
22    "Mantap, pengemasan rapi",
23    "Produknya keren sekali",
24    "Barang memuaskan dan berkualitas",
25    "Suka banget sama produk ini",
26    "Pengalaman belanja yang menyenangkan",
27    "Nilai plus buat kualitas dan pelayanan",
28    "Tidak menyesal membeli produk ini",
29    "Benar-benar memuaskan dan awet",
30    "Hasil sesuai yang diharapkan",
31    "Barang bagus dan original",
32    "Kualitas premium dengan harga terjangkau",
33    "Keren banget, love it",
34    "Review positif dari saya",
35    "Sangat membantu kebutuhan saya",
36    "Packaging oke, isi mantap",
37    "Mantap, terbaik pokoknya"
38 ]
```

```

39
40 negatives = [
41     "Sangat mengecewakan dan buruk",
42     "Barang rusak saat diterima",
43     "Tidak sesuai deskripsi",
44     "Kualitas jelek dan tidak layak",
45     "Pelayanan buruk sekali",
46     "Kecewa berat dengan produk ini",
47     "Pengiriman lambat dan tidak aman",
48     "Barang cacat dan mahal",
49     "Saya tidak akan beli lagi",
50     "Parah, jangan beli produk ini",
51     "Sama sekali tidak memuaskan",
52     "Barang hancur dalam paket",
53     "Komplain tidak ditanggapi",
54     "Salah kirim dan respon lambat",
55     "Produknya murahan",
56     "Gambar tidak sesuai kenyataan",
57     "Material rapuh dan cepat rusak",
58     "Pelayanan mengecewakan",
59     "Barang tertukar dan lambat datang",
60     "Jelek banget, nyesel beli",
61     "Tidak layak pakai",
62     "Overpriced dan kualitas buruk",
63     "Beli sekali dan kapok",
64     "Pelayanan customer tidak membantu",
65     "Respon sangat lambat",
66     "Barang palsu dan rusak",
67     "Paket datang kosong",
68     "Kotor dan berdebu saat diterima",
69     "Barang lama tidak dikirim",
70     "Sangat tidak profesional"
71 ]
72

```

```

73 neutrals = [
74     "Produk cukup baik tapi biasa saja",
75     "Pengalaman belanja standar",
76     "Tidak buruk, tidak juga luar biasa",
77     "Barang sesuai harga",
78     "Cukup oke tapi bisa lebih baik",
79     "Produk seperti pada umumnya",
80     "Barang datang tepat waktu",
81     "Kualitas sesuai harga",
82     "Standar, tidak mengecewakan",
83     "Biasa aja sih",
84     "Netral, tidak puas tapi juga tidak kecewa",
85     "Barang oke untuk pemakaian ringan",
86     "Produk wajar sesuai ekspektasi",
87     "Beli karena perlu saja",
88     "Fungsional tapi tidak istimewa",
89     "Lumayan lah untuk harga segini",
90     "Oke buat kebutuhan sehari-hari",
91     "Tidak ada yang spesial",
92     "Barang datang sesuai pesanan",
93     "Produk lumayan, bisa ditoleransi",
94     "Ya, lumayan sih",
95     "Tidak terlalu mengecewakan",
96     "Pengalaman netral saja",
97     "Produk tidak buruk, hanya standar",
98     "Isi sesuai pesanan",
99     "Kualitas menengah",
100    "Tidak sebaik harapan, tapi oke",
101    "Seperti produk biasa lainnya",
102    "Pengalaman belanja normal",
103    "Barang tidak mengejutkan"
104 ]

```

```

105
106 # Gabungkan data dan label
107 texts = positives + negatives + neutrals
108 labels = ['Positif']*30 + ['Negatif']*30 + ['Netral']*30
109
110 # TF-IDF Vectorization
111 vectorizer = TfidfVectorizer()
112 X = vectorizer.fit_transform(texts)
113 y = labels
114
115 # Stratified split
116 X_train, X_test, y_train, y_test = train_test_split(
117     X, y, test_size=0.3, stratify=y, random_state=42
118 )
119
120 # Logistic Regression model (lebih kuat dari Naive Bayes)
121 model = LogisticRegression(max_iter=300)
122 model.fit(X_train, y_train)
123 y_pred = model.predict(X_test)
124
125 # Evaluasi
126 print("Classification Report:")
127 print(classification_report(y_test, y_pred, zero_division=0))
128 accuracy = accuracy_score(y_test, y_pred)
129 print(f"Akurasi: {accuracy * 100:.2f}%")

```

Output program

```

Classification Report:
              precision    recall  f1-score   support

   Negatif         0.80      0.89      0.84         9
    Netral         0.89      0.89      0.89         9
   Positif         0.75      0.67      0.71         9

 accuracy          0.81
 macro avg         0.81      0.81      0.81
weighted avg         0.81      0.81      0.81

Akurasi: 81.48%

```

Gambar 3. Laporan Klasifikasi dan Evaluasi Akurasi Model

Gambar 3 menunjukkan laporan klasifikasi dan evaluasi akurasi model analisis sentimen terhadap tiga kelas: Negatif, Netral, dan Positif. Model mencapai akurasi keseluruhan sebesar 81.48%, yang menunjukkan kinerja cukup baik. Kelas Netral memiliki precision dan recall tertinggi sebesar 0.89, diikuti oleh kelas Negatif dengan f1-score sebesar 0.84. Sementara itu, kelas Positif menunjukkan performa yang lebih rendah, terutama pada recall (0.67), yang berarti beberapa ulasan positif tidak terdeteksi dengan baik oleh model. Nilai macro average dan weighted average yang sama (0.81) mencerminkan distribusi kelas yang seimbang dan performa model yang stabil di ketiga kategori sentimen. Hasil ini menunjukkan bahwa model cukup efektif dalam mengidentifikasi berbagai jenis sentimen dalam ulasan produk, meskipun masih perlu penyempurnaan pada deteksi sentimen positif. Laporan ini menjadi dasar evaluasi penting untuk meningkatkan model melalui optimasi fitur atau teknik pelatihan lanjutan..

3. Studi Kasus

Pada bagian ini, kita akan membahas dampak dari integrasi fitur yang menggunakan teknik TF-IDF, N-Gram,

dan Word2Vec terhadap performa model Support Vector Machine (SVM) dalam analisis sentimen. Dalam analisis sentimen pada ulasan produk e-commerce, model SVM sering kali digunakan karena kemampuannya untuk menangani data dengan dimensi tinggi dan ketidakseimbangan kelas yang sering ditemukan dalam dataset ulasan.

Ketika fitur-fitur dari teknik ekstraksi TF-IDF, N-Gram, dan Word2Vec digabungkan, kualitas representasi data meningkat secara signifikan. Penggabungan ini memungkinkan model untuk memanfaatkan keunggulan masing-masing teknik: TF-IDF menyoroti kata-kata penting, N-Gram menangkap pola frasa, dan Word2Vec menyoroti makna semantik dari kata-kata. Dengan menggabungkan fitur-fitur ini, model SVM menjadi lebih sensitif dalam mendeteksi sentimen yang terkandung dalam teks ulasan, baik itu positif, negatif, atau netral.

Dampak dari integrasi fitur ini terhadap F1-score model SVM sangat signifikan. F1-score, yang merupakan rata-rata harmonis antara precision dan recall, menjadi indikator penting dalam mengevaluasi kinerja model, terutama ketika dataset tidak seimbang. Dengan integrasi fitur yang lebih komprehensif, SVM dapat lebih baik dalam mengidentifikasi sentimen negatif yang sering kali kurang

terwakili dalam dataset, serta meningkatkan akurasi dalam mengklasifikasikan sentimen positif dan netral.

Dalam studi kasus yang dilakukan, setelah integrasi fitur, F1-score model SVM meningkat, menunjukkan bahwa penggabungan fitur ini memperbaiki kinerja model dalam mendeteksi sentimen dengan lebih akurat, memberikan hasil yang lebih representatif, dan mengurangi kesalahan klasifikasi.

4. Soal Latihan

1. Jelaskan konsep dasar dari TF-IDF, N-Gram, dan Word2Vec. Bagaimana masing-masing teknik ini berkontribusi dalam proses ekstraksi fitur untuk analisis sentimen? Berikan contoh aplikasinya dalam ulasan produk e-commerce.
2. Apa keunggulan dan tantangan yang dihadapi dalam mengintegrasikan fitur dari berbagai teknik ekstraksi seperti TF-IDF, N-Gram, dan Word2Vec? Jelaskan bagaimana fungsi `scipy.sparse.hstack` membantu dalam proses penggabungan fitur ini.
3. Analisis bagaimana penggabungan fitur multimodal yang melibatkan TF-IDF, N-Gram, dan Word2Vec dapat mempengaruhi performa model SVM dalam analisis

- sentimen. Apa dampaknya terhadap F1-score model dan bagaimana itu menunjukkan peningkatan kinerja?
4. Mengapa normalisasi fitur penting dalam proses pelatihan model analisis sentimen, terutama setelah penggabungan fitur dari berbagai teknik ekstraksi? Jelaskan bagaimana teknik MinMaxScaler dapat membantu dalam menyeimbangkan bobot fitur.
 5. Berikan interpretasi dari hasil klasifikasi sentimen menggunakan model SVM setelah integrasi fitur TF-IDF, N-Gram, dan Word2Vec. Apa yang dapat disimpulkan dari output yang menunjukkan akurasi 100% dan F1-score yang sempurna?

Daftar Pustaka

- Barunaha, A., Prakash, M., & Naresh, R. (2023). Real-time sentiment analysis of social media content for brand improvement and topic tracking. *Proceedings of the International Conference on Business and Technology*, 26-31. https://doi.org/10.2991/978-94-6463-250-7_6
- Zhang, J., & Maskat, R. (2024). A word order framework for Mandarin sentiment analysis of social media text. *Frontiers in Artificial Intelligence and Applications*, 241218. <https://doi.org/10.3233/faia241218>

Konsep Ketidakseimbangan Kelas

1. Konsep Dasar

Ketidakseimbangan kelas menggambarkan kondisi di mana proporsi antara label dalam suatu kumpulan data tidak terdistribusi secara merata, sering kali menjadi tantangan dalam membangun sistem klasifikasi berbasis pembelajaran mesin. Ketimpangan ini menciptakan representasi data yang tidak sejalan dengan variasi sebenarnya, terutama ketika salah satu kelas lebih dominan dari yang lain. Dalam ranah e-commerce, misalnya, sentimen positif dari konsumen terhadap produk tertentu dapat mencakup lebih dari delapan puluh persen dari seluruh ulasan, sedangkan ekspresi negatif atau netral hanya mengisi sebagian kecil sisanya. Keadaan tersebut mengakibatkan sistem yang dikembangkan menjadi terlalu terfokus pada pola yang berulang dari data yang mendominasi. Ketika dihadapkan pada masukan dari kelompok data yang kurang terwakili, sistem menjadi kesulitan dalam mengidentifikasi karakteristik yang berbeda secara akurat. Hal ini tidak hanya menurunkan kinerja klasifikasi, melainkan juga berisiko menutupi pesan-pesan yang penting dari pengguna. Oleh karena itu, membangun sistem yang tidak hanya akurat untuk data dominan,

melainkan juga tanggap terhadap informasi yang muncul dalam frekuensi yang lebih rendah, menjadi landasan penting dalam menciptakan pengambilan keputusan yang adil dan menyeluruh.

Model klasifikasi yang dilatih menggunakan data dengan distribusi tidak merata akan belajar lebih intens terhadap pola yang muncul dalam kelas mayoritas. Hal ini menyebabkan model lebih mudah mengenali dan mengelompokkan data ke dalam kategori tersebut, bahkan ketika sebenarnya data termasuk ke dalam kelas yang berbeda. Akibatnya, akurasi keseluruhan yang tinggi bisa menyesatkan, karena sistem gagal mengenali kelas minoritas dengan baik. Fenomena ini dikenal sebagai prediksi bias, di mana model menjadi kurang peka terhadap representasi minoritas dalam dataset. Dalam implementasinya, hal ini tidak hanya berdampak pada performa model dari sisi teknis, tetapi juga berdampak terhadap kualitas pengalaman pengguna ketika sistem tidak mampu mengidentifikasi keluhan atau ekspresi negatif secara akurat.

Dalam konteks evaluasi kinerja model klasifikasi, ketidakseimbangan kelas juga memengaruhi keandalan metrik evaluatif. Akurasi sebagai indikator umum bisa memberikan gambaran keliru tentang keberhasilan model dalam pengklasifikasian data. Misalnya, pada dataset yang

terdiri dari 1000 ulasan, jika 950 di antaranya bernada positif dan hanya 50 yang bernada negatif, sebuah model yang mengklasifikasikan seluruh ulasan sebagai positif tetap akan mendapatkan nilai akurasi sebesar 95%. Meskipun tampaknya sangat baik, model tersebut sama sekali tidak memiliki kemampuan dalam mengidentifikasi kelas negatif. Oleh karena itu, metrik seperti F1-score, precision, dan recall menjadi lebih relevan karena mereka memberikan penilaian yang lebih adil terhadap kinerja sistem terhadap kelas yang lebih sedikit.

Kesenjangan representasi kelas ini bukan hanya persoalan teknis semata, tetapi juga menyangkut keadilan dalam pemrosesan data. Dalam ekosistem digital yang semakin berorientasi pada pengguna, penting untuk memastikan bahwa setiap ekspresi, baik mayoritas maupun minoritas, memiliki peluang yang sama untuk diproses dan ditanggapi oleh sistem. Sebuah sistem yang mampu mengenali komentar positif dengan baik, namun gagal membaca nada frustrasi, ketidakpuasan, atau kritik halus dari konsumen, pada akhirnya tidak akan memberikan kontribusi maksimal dalam pengambilan keputusan yang berbasis suara pengguna. Oleh karena itu, ketidakseimbangan kelas memerlukan perhatian serius agar sistem tidak hanya efisien secara teknis, tetapi juga inklusif dalam memahami dinamika ekspresi konsumen.

Berbagai pendekatan telah dikembangkan untuk mengatasi tantangan ini, di antaranya adalah pemanfaatan teknik pembobotan kelas saat proses pelatihan, serta strategi resampling yang dapat memperkuat representasi kelas minoritas tanpa mengganggu keseimbangan informasi. Pembobotan kelas memberikan bobot lebih besar pada kesalahan prediksi di kelas minoritas, sehingga mendorong model untuk lebih peka terhadap pola yang muncul dari segmen tersebut. Strategi ini efektif dalam memberikan sinyal tambahan pada model bahwa kelas minoritas memerlukan perhatian yang lebih besar dibanding kelas dominan.

Di sisi lain, resampling menjadi solusi yang juga banyak diterapkan, baik dalam bentuk oversampling terhadap kelas minoritas, maupun undersampling terhadap kelas mayoritas. Salah satu pendekatan populer adalah teknik SMOTE yang menggenerasi sampel sintetis berdasarkan tetangga terdekat dalam kelas minoritas. Teknik ini membantu memperkaya variasi data tanpa mengubah jumlah data mayoritas. Namun, SMOTE juga memiliki keterbatasan, terutama ketika data minoritas mengandung noise atau ketika titik-titik data berada di area yang tumpang tindih dengan kelas lain. Oleh karena itu, penggabungan SMOTE dengan teknik lain seperti ENN (Edited Nearest Neighbor), yang bertugas menyaring data

berdasarkan jarak dari tetangga terdekat, dianggap mampu meningkatkan kualitas representasi dan menghasilkan dataset yang lebih bersih dan seimbang.

Implementasi gabungan ini, yang dikenal sebagai SMOTEENN, memperlihatkan peningkatan performa klasifikasi pada berbagai studi kasus. SMOTE membantu memperluas keberadaan kelas minoritas, sementara ENN membersihkan ambiguitas yang dapat mengganggu keakuratan klasifikasi. Dalam penerapan di domain e-commerce, gabungan ini sangat relevan karena opini konsumen tidak selalu bersifat eksplisit. Ekspresi ketidakpuasan bisa muncul dalam bentuk yang sangat halus, dan model yang hanya mengandalkan dominasi data positif akan melewati nuansa tersebut. Dengan pendekatan gabungan, sistem menjadi lebih adaptif dalam menangkap keragaman ekspresi yang ada.

Keseimbangan distribusi kelas juga berdampak pada aspek representasi fitur dalam proses pembelajaran. Teknik seperti TF-IDF, N-Gram, dan Word2Vec, meskipun kuat dalam mengungkapkan makna kata dan pola dalam teks, tetap terpengaruh oleh dominasi frekuensi kelas. Kata-kata yang sering muncul dalam ulasan positif akan mendominasi bobot fitur, menyebabkan informasi dari ulasan negatif menjadi kurang terlihat. Oleh karena itu, penggabungan fitur dari berbagai teknik, yang kemudian diintegrasikan ke

dalam satu representasi numerik melalui matriks sparse, harus disertai dengan langkah-langkah normalisasi agar tidak terjadi ketimpangan dalam pengaruh fitur terhadap model klasifikasi.

Dalam proses penyusunan fitur tersebut, penerapan penggabungan berbasis `scipy.sparse.hstack` menjadi langkah teknis yang efisien karena mampu menggabungkan berbagai bentuk representasi numerik tanpa mengorbankan efisiensi komputasi. Namun, tantangan tidak hanya terletak pada sisi teknis penggabungan, tetapi juga dalam menjaga kesetaraan kontribusi informasi dari setiap kelas. Normalisasi seperti `MinMaxScaler` berfungsi untuk menyeimbangkan skala nilai antar fitur sehingga model tidak memberikan bobot berlebihan pada fitur yang berasal dari kelas dominan.

Ketika model yang telah dilatih dengan representasi seimbang diuji, hasil evaluasi menunjukkan bahwa sensitivitas terhadap kelas minoritas meningkat secara signifikan. Meskipun akurasi secara keseluruhan tidak mengalami lonjakan drastis, F1-score dan recall untuk kelas minoritas memperlihatkan peningkatan yang nyata. Misalnya, recall pada kelas minoritas mencapai 85% meskipun precision masih pada angka 52%, menandakan bahwa sistem lebih peka dalam mengenali sinyal dari kelas kecil, meskipun masih perlu perbaikan dalam menghindari

kesalahan klasifikasi. Nilai macro average F1-score yang meningkat menegaskan bahwa representasi seimbang memberikan kontribusi terhadap keadilan dan ketepatan model secara keseluruhan.

a) **Imbalance Kelas dalam Analisis Sentimen**

Dalam analisis sentimen, terutama pada ulasan produk di e-commerce, ketidakseimbangan kelas sering kali terjadi, dengan ulasan positif yang lebih banyak dibandingkan ulasan negatif. Masalah ini mempengaruhi pelatihan model, karena model cenderung lebih mudah memprediksi ulasan positif, sementara prediksi untuk ulasan negatif atau netral menjadi buruk. Jika sebagian besar data pelatihan adalah ulasan positif, model akan menganggap label positif sebagai pilihan "aman", sehingga ulasan negatif sering salah diklasifikasikan sebagai positif. Akibatnya, prediksi model menjadi bias, dengan ulasan negatif dan netral hampir selalu terabaikan (Mascii et al., 2021).

b) **Penyebab Ketidakseimbangan Kelas**

Ketidakseimbangan kelas dalam analisis sentimen dapat disebabkan oleh berbagai faktor. Salah satunya adalah kecenderungan konsumen untuk memberikan ulasan positif, terutama pada produk yang sudah terkenal kualitasnya, sementara produk baru atau

kurang populer sering mendapatkan ulasan negatif. Selain itu, algoritma platform e-commerce yang mendorong ulasan positif atau promosi yang meningkatkan kepuasan pelanggan juga berperan dalam menciptakan ketidakseimbangan. Keterbatasan dalam pengumpulan data, di mana ulasan negatif lebih sulit diakses atau kurang diperhatikan, juga menjadi faktor penyebab. Semua ini dapat mempengaruhi akurasi dan efektivitas model analisis sentimen (Mascii et al., 2021).

Dampak Ketidakseimbangan Kelas terhadap Bias Model

Ketidakseimbangan kelas dalam dataset dapat memengaruhi kinerja dan bias model klasifikasi secara signifikan. Pada dataset yang tidak seimbang, model cenderung lebih sensitif terhadap kelas mayoritas dan kurang mengenali kelas minoritas. Dalam analisis sentimen e-commerce, seperti ulasan produk, model yang tidak ditangani dengan baik bisa menghasilkan prediksi yang bias, terutama ketika ulasan positif jauh lebih banyak daripada ulasan negatif. Hal ini mengarah pada masalah seperti akurasi yang menyesatkan, di mana model bisa tampak efektif meskipun gagal mendeteksi ulasan negatif yang penting. Untuk evaluasi yang lebih tepat, metrik

seperti precision, recall, dan F1-score lebih relevan daripada sekadar akurasi (Mascii et al., 2021).

Mengatasi Ketidakseimbangan Kelas

Untuk mengatasi dampak ketidakseimbangan kelas dan bias yang ditimbulkan, beberapa teknik dapat diterapkan dalam pengolahan data dan pelatihan model. Salah satu pendekatan yang paling umum adalah resampling, yang terdiri dari dua teknik utama: oversampling dan undersampling.

a) Oversampling dan SMOTE

Oversampling adalah teknik untuk meningkatkan jumlah sampel pada kelas minoritas dengan menyalin data yang ada atau menciptakan data sintetis. Salah satu metode oversampling yang terkenal adalah Synthetic Minority Over-sampling Technique (SMOTE), yang menghasilkan data sintetis melalui interpolasi antara sampel yang ada. Dengan meningkatkan jumlah sampel kelas minoritas, seperti ulasan negatif, SMOTE dapat membantu model mengenali kelas minoritas lebih baik dan mengurangi bias terhadap kelas mayoritas. Penggunaan teknik ini penting untuk meningkatkan kinerja model klasifikasi, terutama dalam kasus dataset yang tidak seimbang (Mascii et al., 2021).

b) **Undersampling dan SMOTEENN**

Undersampling adalah teknik untuk mengurangi jumlah sampel pada kelas mayoritas agar distribusi kelas menjadi lebih seimbang. Meskipun efektif, teknik ini bisa mengorbankan informasi penting dari kelas mayoritas. Sebagai alternatif, SMOTEENN (kombinasi SMOTE dan Edited Nearest Neighbors) dapat digunakan. SMOTEENN menggabungkan keuntungan dari SMOTE dalam menambah sampel pada kelas minoritas dengan kemampuan Edited Nearest Neighbors (ENN) untuk membersihkan data dengan menghapus sampel yang tidak relevan dari kelas mayoritas. Dengan cara ini, SMOTEENN tidak hanya menyeimbangkan jumlah sampel, tetapi juga meningkatkan kualitas data dan akurasi model dalam mengklasifikasikan kelas minoritas (Mascii et al., 2021).

c) **Pemilihan Model yang Tepat**

Pemilihan model yang tepat sangat penting dalam mengatasi ketidakseimbangan kelas. Beberapa model klasifikasi, seperti Support Vector Machines (SVM) dan Decision Trees, dapat menangani ketidakseimbangan kelas dengan lebih efektif. Model-model ini memungkinkan optimasi fungsi kerugian untuk memberikan bobot lebih besar pada kelas minoritas, sehingga model lebih sensitif terhadap kelas yang lebih

sedikit. Pendekatan ini membantu meningkatkan kinerja model dalam mengklasifikasikan kelas minoritas tanpa mengorbankan akurasi keseluruhan. Dengan memilih model yang tepat, ketidakseimbangan kelas dapat diatasi lebih baik, menghasilkan prediksi yang lebih adil dan akurat (Mascii et al., 2021).

Kombinasi teknik resampling dan pemilihan model yang tepat dapat membantu menghasilkan model yang lebih seimbang dan akurat dalam analisis sentimen, khususnya dalam ulasan produk e-commerce. Ketidakseimbangan kelas, di mana ulasan positif jauh lebih banyak daripada ulasan negatif, menyebabkan model lebih cenderung memprediksi kelas mayoritas, mengabaikan kelas minoritas, dan menghasilkan kesalahan klasifikasi. Hal ini sangat berbahaya, terutama dalam mendeteksi masalah produk atau layanan yang bisa mempengaruhi reputasi perusahaan. Dengan menggunakan teknik seperti SMOTE, SMOTEENN, dan memilih model yang tepat, ketidakseimbangan kelas dapat diatasi, meningkatkan akurasi dan memberikan wawasan lebih baik bagi perusahaan (Mascii et al., 2021).

2. Aplikasi

Analisis distribusi kelas sangat penting dalam dataset yang mengalami ketidakseimbangan kelas, dan salah satu cara yang efektif untuk melakukannya di Python adalah menggunakan pustaka `Counter()` dari modul `collections`. Fungsi `Counter()` memungkinkan kita untuk menghitung frekuensi kemunculan setiap elemen dalam suatu koleksi data, seperti list atau array. Dalam konteks analisis sentimen pada ulasan produk, `Counter()` dapat digunakan untuk menganalisis distribusi kelas dalam dataset yang digunakan untuk melatih model pembelajaran mesin. Pemahaman distribusi kelas membantu dalam mengidentifikasi masalah ketidakseimbangan yang dapat mempengaruhi kinerja model.

Kode Program Python

Berikut adalah contoh kode Python untuk menghitung distribusi kelas dalam dataset yang berisi label kelas "positif" dan "negatif":

```

1 from collections import Counter
2
3 # Contoh dataset label kelas (misalnya hasil analisis sentimen)
4 labels = ['positif', 'negatif', 'positif', 'positif', 'negatif', 'positif', 'negatif', 'positif', 'positif']
5
6 # Menggunakan Counter untuk menghitung distribusi kelas
7 distribusi = Counter(labels)
8
9 # Menampilkan hasil distribusi kelas
10 print("Distribusi Kelas: ", distribusi)
11

```

Distribusi Kelas: Counter({'positif': 6, 'negatif': 3})


Output Kode Program

Output "Distribusi Kelas: Counter({'positif': 6, 'negatif': 3})" menunjukkan hasil distribusi kelas dari dataset yang diberikan. Counter menghitung jumlah kemunculan masing-masing label kelas dalam dataset. Dalam hal ini, label "positif" muncul 6 kali, sementara label "negatif" muncul 3 kali. Ini mengindikasikan bahwa dalam dataset yang terdiri dari 9 elemen, mayoritas ulasan memiliki sentimen positif. Output ini memberi gambaran tentang ketidakseimbangan kelas, di mana kelas "positif" lebih dominan. Analisis distribusi kelas seperti ini penting dalam pemodelan machine learning, terutama untuk menangani masalah ketidakseimbangan kelas. (Mascii et al., 2021).

3. Studi Kasus

Dalam analisis ketidakseimbangan kelas, visualisasi distribusi kelas sebelum melakukan resampling sangat

penting untuk memahami sejauh mana ketidakseimbangan dalam dataset. Sebelum melakukan teknik penyeimbangan seperti oversampling atau undersampling, kita perlu mengetahui seberapa dominan kelas mayoritas dan seberapa sedikit kelas minoritas.



Gambar 4. Distribusi Kelas Sebelum Resampling dan sesudah

Gambar 4 menunjukkan dua grafik yang memperlihatkan distribusi kelas dalam dataset sebelum dan sesudah dilakukan resampling. Grafik di sebelah kiri menunjukkan distribusi kelas sebelum resampling, di mana jelas terlihat dominasi kelas "positif". Kelas "positif" menempati hampir seluruh dataset, dengan jumlah yang jauh lebih tinggi dibandingkan dengan kelas "negatif" dan "netral", yang sangat sedikit jumlahnya. Hal ini menggambarkan ketidakseimbangan kelas yang ekstrem dalam dataset. Dengan menggunakan visualisasi ini, kita

bisa langsung melihat bahwa model yang dilatih pada data ini cenderung akan memprediksi kelas mayoritas (positif) dengan sangat tinggi, sementara kelas "negatif" dan "netral" hampir tidak terdeteksi. Ini akan mempengaruhi kinerja model, mengarah pada prediksi yang bias, terutama terhadap kelas minoritas yang kurang terwakili.

Perubahan Setelah SMOTEENN

Grafik di sebelah kanan menunjukkan distribusi kelas setelah diterapkan teknik SMOTEENN (kombinasi SMOTE dan Edited Nearest Neighbors). Setelah resampling, kelas "positif", "negatif", dan "netral" kini lebih seimbang. SMOTEENN berhasil meningkatkan jumlah ulasan untuk kelas minoritas, seperti "negatif" dan "netral", sehingga model dapat mempelajari semua kelas secara adil dan akurat. Visualisasi ini menunjukkan bahwa teknik resampling yang tepat dapat menyeimbangkan distribusi kelas dalam dataset, meningkatkan kemampuan model untuk memprediksi kelas minoritas dengan lebih efektif. Penggunaan SMOTEENN membantu mengurangi bias terhadap kelas mayoritas dan meningkatkan kinerja model

4. Soal Latihan

- 1) Jelaskan apa yang dimaksud dengan ketidakseimbangan kelas dalam dataset dan

bagaimana hal ini dapat memengaruhi kinerja model pembelajaran mesin, terutama dalam konteks analisis sentimen di e-commerce. Berikan contoh distribusi kelas yang tidak seimbang pada dataset ulasan produk dan bagaimana hal tersebut dapat mempengaruhi prediksi model.

- 2) Apa saja penyebab utama dari ketidakseimbangan kelas dalam dataset? Jelaskan bagaimana faktor-faktor seperti kecenderungan konsumen untuk memberikan ulasan positif, karakteristik produk, dan pengaruh algoritma platform e-commerce dapat menyebabkan distribusi kelas yang tidak seimbang dalam analisis sentimen.
- 3) Bagaimana bias yang muncul akibat ketidakseimbangan kelas dapat mempengaruhi evaluasi model? Diskusikan mengapa metrik seperti akurasi saja tidak cukup untuk mengevaluasi model pada dataset yang tidak seimbang, dan sebutkan metrik apa saja yang lebih relevan untuk digunakan.
- 4) Jelaskan konsep SMOTE dan SMOTEENN dalam menangani ketidakseimbangan kelas. Bagaimana kedua teknik ini bekerja, dan apa perbedaan mendasar antara keduanya? Berikan contoh bagaimana penerapan teknik-teknik ini dapat meningkatkan kinerja model dalam analisis sentimen.

- 5) Dalam konteks visualisasi distribusi kelas sebelum dan sesudah resampling, apa yang dapat disimpulkan dari grafik yang menunjukkan dominasi kelas mayoritas sebelum resampling dan distribusi yang lebih seimbang setelah penerapan teknik SMOTEENN? Jelaskan mengapa penting untuk memvisualisasikan distribusi kelas dalam proses pelatihan model.

Daftar Pustaka

- Barunaha, A., Prakash, M., & Naresh, R. (2023). *Real-time sentiment analysis of social media content for brand improvement and topic tracking*. 26-31. https://doi.org/10.2991/978-94-6463-250-7_6
- Basile, V., Croce, D., Maro, M., & Passaro, L. (2020). *Preface to the evalita 2020 proceedings*. 1-1. <https://doi.org/10.4000/books.aaccademia.6737>
- Denecke, K. (2022). *Does enrichment of clinical texts by ontology concepts increases classification accuracy?* <https://doi.org/10.3233/shti220148>
- Mascii, L., Luschi, A., & Iadanza, E. (2021). *Sentiment analysis for performance evaluation of maintenance in healthcare*. 359-367. https://doi.org/10.1007/978-3-030-73909-6_41

Ujian Tengah Semester

5 Soal Praktikum (Tugas Praktikum - 30%)

Implementasi Coding dengan Python

1. Preprocessing Teks Ulasan

Tugas:

Lakukan preprocessing pada teks: "Barangnya keren bgt tp harganya mahal :("

Langkah:

1. Normalisasi slang
(bgt → banget, tp → tapi)
2. Tokenisasi
3. Stopword removal (gunakan daftar: ["yang", "di", "yg", "dg", "tp"])
4. Stemming dengan Sastrawi

Output: Daftar token hasil preprocessing.

2. TF-IDF dengan Scikit-Learn

Tugas:

Hitung vektor TF-IDF untuk 2 dokumen:

["Pengiriman cepat, produk sesuai gambar",
"Pengiriman lambat, produk tidak sesuai"]

Parameter: ngram_range=(1,2), max_features=5

Output: Matriks TF-IDF dan daftar fitur terpilih.

3. **Word2Vec dan Visualisasi**

Tugas:

Latih model Word2Vec sederhana dengan data:

python

```
sentences = [["saya", "puas", "produk", "ini"],  
["saya", "kecewa", "beli", "produk", "itu"]]
```

Parameter: vector_size=5, window=2, min_count=1

Output: Vektor untuk kata "puas" dan "kecewa".

4. **SMOTE untuk Ketidakseimbangan Kelas**

Tugas:

Dataset:

python

```
X = [[0.1], [0.2], [0.3], [0.4], [0.5]] # Fitur
```

```
y = [0, 0, 0, 0, 1] # Label (kelas minoritas=1)
```

Terapkan SMOTE untuk menambah sampel kelas minoritas (rasio=0.5).

Output: Jumlah sampel sebelum dan sesudah SMOTE.

5. **Integrasi Fitur Multimodal**

Tugas:

Gabungkan matriks:

TF-IDF (bentuk sparse): $\begin{bmatrix} 0.8 & 0.2 \\ 0.4 & 0.6 \end{bmatrix}$

Word2Vec (dense): $[[0.1, 0.3], [0.2, 0.4]]$

Gunakan `scipy.sparse.hstack` dan konversi Word2Vec ke sparse.

Output: Matriks gabungan dalam bentuk array.

10 Soal Essay (UTS - 20%)

Analisis Konseptual dan Problem-Solving

1. Jelaskan mengapa ulasan negatif seringkali lebih bernilai bisnis daripada ulasan positif bagi e-commerce! Berikan contoh strategi respons berdasarkan analisis sentimen!
2. Mengapa normalisasi slang (e.g., 'bgt' → 'banget') dan stemming dengan Sastrawi kritikal dalam NLP bahasa Indonesia? Bandingkan dengan preprocessing untuk bahasa Inggris!
3. Analisis mengapa bigram seperti 'tidak puas' lebih informatif daripada unigram 'puas' dalam TF-IDF! Berikan contoh perhitungan bobotnya!"
4. Jelaskan bagaimana vektor Word2Vec menangkap relasi semantik kata 'puas' dan 'kecewa'! Mengapa operasi vektor 'puas' - 'senang' + 'marah' tidak valid?
5. Mengapa akurasi 85% pada dataset tidak seimbang (80% positif) bisa menyesatkan? Hitung recall kelas minoritas (negatif) jika model hanya memprediksi 1

ulasan negatif dengan benar dari total 5 ulasan negatif!"

6. Jelaskan prinsip kerja hybrid SMOTEENN! Mengapa teknik ini lebih efektif menangani sampel ambigu daripada SMOTE standalone?
7. Ketika F1-score kelas negatif=0.25, apa artinya bagi bisnis? Rekomendasikan dua strategi teknis untuk meningkatkannya!
8. Desain pipeline dari preprocessing hingga klasifikasi untuk dataset Skin Care X! Sertakan alasan pemilihan TF-IDF + Word2Vec!
9. Mengapa model yang dilatih dengan data Shopee (dominan positif) gagal di Tokopedia (seimbang)?
Proposalkan solusi transfer learning!
10. Identifikasi pola sentimen 'tekstur lengket' pada produk skincare. Rancang langkah produkt development (R&D) dan komunikasi pelanggan berdasarkan insight ini!

Kunci Penilaian

Praktikum:

1. Ketepatan sintaksis (50%).
2. Ketepatan output (50%).

Essay:

1. Kedalaman analisis (40%).

2. Relevansi solusi (30%).
3. Contoh konkret (30%).

Catatan:

1. Tugas praktikum menguji implementasi teknis (Pertemuan 2-7).
2. Soal essay menguji pemahaman holistik (Pertemuan 1-7) dan kemampuan strategis.

Teknik Resampling (SMOTE)

1. Konsep Dasar

Ketidakseimbangan kelas dalam analisis data klasifikasi terjadi ketika kelas mayoritas memiliki jumlah sampel yang jauh lebih banyak dibandingkan kelas minoritas. Kondisi ini menyebabkan model cenderung memprediksi kelas mayoritas dan kesulitan mendeteksi pola atau karakteristik kelas minoritas. Masalah ini sering ditemui dalam berbagai aplikasi, seperti analisis sentimen atau deteksi penipuan, di mana kelas minoritas sering kali menjadi fokus utama. Untuk mengatasi ketidakseimbangan kelas, teknik resampling seperti SMOTE (Synthetic Minority Over-sampling Technique) digunakan. SMOTE menghasilkan sampel sintetis untuk kelas minoritas dengan cara interpolasi antara sampel yang ada, bukan sekadar menggandakan data yang ada, sehingga dapat meningkatkan keberagaman dataset tanpa menyebabkan overfitting. Teknik ini memperkaya informasi kelas minoritas, memungkinkan model untuk lebih efektif dalam mengenali pola dan karakteristiknya. Dengan demikian, SMOTE membantu meningkatkan kinerja model dalam menghadapi ketidakseimbangan kelas yang ada, seperti

yang dijelaskan oleh Gøttcke & Zimek (2021) dan Kong et al. (2020)..

Keuntungan Penggunaan SMOTE

Keuntungan penggunaan SMOTE (Synthetic Minority Over-sampling Technique) dalam menangani ketidakseimbangan kelas sangat signifikan dibandingkan metode tradisional. Pertama, SMOTE menghindari kehilangan informasi penting yang terjadi pada undersampling, karena tidak mengurangi jumlah sampel kelas mayoritas (Kong et al., 2020). Kedua, dengan menambah jumlah sampel pada kelas minoritas, SMOTE meningkatkan kinerja model dalam hal akurasi, precision, recall, dan F1-score, terutama pada sentimen negatif atau kelas minoritas (Kong et al., 2020). Ketiga, SMOTE memungkinkan model untuk lebih baik dalam menggeneralisasi data baru (Gøttcke & Zimek, 2021). Keempat, SMOTE menstabilkan model dengan menciptakan dataset yang lebih seimbang, sehingga prediksi lebih akurat (Kong et al., 2020)..

Tantangan dan Keterbatasan dalam Penggunaan SMOTE

Meskipun SMOTE menawarkan berbagai keuntungan dalam penanganan ketidakseimbangan data, teknik ini juga

menghadapi beberapa tantangan. Pertama, SMOTE dapat menghasilkan sampel sintetis yang tidak realistis, terutama jika data mengandung noise atau outliers, yang dapat merugikan model (Gøttcke & Zimek, 2021). Kedua, penambahan sampel sintetis meningkatkan kompleksitas model, memperpanjang waktu pelatihan, dan membutuhkan lebih banyak sumber daya komputasi, serta mungkin memerlukan penyesuaian algoritma klasifikasi (Kong et al., 2020). Ketiga, penggunaan SMOTE secara berlebihan dapat menyebabkan overfitting pada kelas minoritas, sehingga mengganggu kemampuan model untuk mengenali pola kelas mayoritas (Gøttcke & Zimek, 2021). Terakhir, SMOTE kurang efektif pada data non-linear, di mana interpolasi antara sampel minoritas dan tetangga terdekat tidak selalu menghasilkan sampel yang representatif (Kong et al., 2020).

Penerapan SMOTE di Berbagai Bidang

SMOTE (Synthetic Minority Over-sampling Technique) telah diterapkan di berbagai bidang untuk mengatasi masalah ketidakseimbangan kelas. Dalam analisis sentimen, SMOTE membantu meningkatkan jumlah ulasan negatif atau netral pada platform e-commerce, sehingga model lebih sensitif terhadap sentimen negatif yang penting (Kong et al., 2020). Pada deteksi penipuan, SMOTE

digunakan untuk memperbanyak sampel transaksi penipuan, meningkatkan kemampuan model dalam mendeteksi penipuan dan mengurangi false negatives (Gøttcke & Zimek, 2021). Di bidang medis, SMOTE memperbaiki diagnosis penyakit langka dengan menambah data untuk deteksi dini yang lebih akurat (Kong et al., 2020). Dalam prediksi kredit, SMOTE meningkatkan representasi konsumen berisiko tinggi untuk akurasi yang lebih baik dalam identifikasi gagal bayar (Gøttcke & Zimek, 2021)

SMOTE dan SMOTEENN

SMOTEENN, versi lanjutan dari SMOTE, menggabungkan teknik Synthetic Minority Over-sampling Technique (SMOTE) dengan Edited Nearest Neighbors (ENN) untuk mengatasi beberapa tantangan yang dihadapi SMOTE. SMOTEENN tidak hanya menghasilkan sampel sintetis untuk kelas minoritas, tetapi juga membersihkan dataset dengan menghapus sampel yang ambigu atau redundan dari kelas mayoritas. Dengan menggabungkan kedua teknik ini, SMOTEENN mampu meningkatkan jumlah sampel minoritas sekaligus memperbaiki kualitas dataset dengan menghilangkan sampel yang tidak relevan atau noise. Penelitian menunjukkan bahwa SMOTEENN lebih

unggul dibandingkan SMOTE dalam menangani dataset yang mengandung noise (Kong et al., 2020).

2. Aplikasi

SMOTE (Synthetic Minority Over-sampling Technique) yang diimplementasikan melalui pustaka `imblearn` di Python merupakan solusi efektif untuk mengatasi ketidakseimbangan kelas pada dataset. Dengan menggunakan kelas `imblearn.over_sampling.SMOTE`, teknik ini meningkatkan jumlah sampel pada kelas minoritas dengan menghasilkan sampel sintesis melalui interpolasi sampel yang ada. Proses ini tidak menghapus data kelas mayoritas, tetapi menambah sampel minoritas secara realistis dan bervariasi. SMOTE memiliki keunggulan dibandingkan teknik oversampling tradisional, yang hanya menggandakan sampel yang ada, dengan kemampuan untuk memperkenalkan variasi baru dalam data minoritas, sehingga memperbaiki kinerja model dalam menghadapi ketidakseimbangan kelas.

Kode Pyhton

```
1 from imblearn.over_sampling import SMOTE
2 from sklearn.model_selection import train_test_split
3 from sklearn.datasets import make_classification
4 # Misalkan kita membuat dataset contoh yang tidak seimbang
5 X, y = make_classification(n_samples=1000, n_features=20, n_classes=2,
6                             weights=[0.75, 0.25], flip_y=0, random_state=42)
7 # Membagi dataset menjadi data pelatihan dan pengujian
8 X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.25, random_state=42)
9 # Inisialisasi SMOTE
10 smote = SMOTE(sampling_strategy='auto', random_state=42)
11 # Terapkan SMOTE pada data pelatihan untuk mengatasi ketidakseimbangan kelas
12 X_res, y_res = smote.fit_resample(X_train, y_train)
13 # Menampilkan distribusi kelas sebelum dan sesudah SMOTE
14 print("Distribusi kelas sebelum SMOTE:")
15 print(f"Kelas 0: {y_train.tolist().count(0)} | Kelas 1: {y_train.tolist().count(1)}")
16 print("Distribusi kelas setelah SMOTE:")
17 print(f"Kelas 0: {y_res.tolist().count(0)} | Kelas 1: {y_res.tolist().count(1)}")
```

Distribusi kelas sebelum SMOTE:

Kelas 0: 557 | Kelas 1: 193

Distribusi kelas setelah SMOTE:

Kelas 0: 557 | Kelas 1: 557

Ouput Program

Output menunjukkan distribusi kelas dalam dataset sebelum dan setelah penerapan SMOTE (Synthetic Minority Over-sampling Technique). Sebelum SMOTE, kelas 0 (mayoritas) memiliki 557 sampel, sementara kelas 1 (minoritas) hanya memiliki 193 sampel, menunjukkan ketidakseimbangan kelas yang signifikan. Setelah SMOTE diterapkan, jumlah sampel untuk kelas 1 ditingkatkan

menjadi 557, sama dengan jumlah kelas 0, sehingga menciptakan keseimbangan antara kedua kelas. Penerapan SMOTE ini penting untuk mengatasi masalah ketidakseimbangan kelas yang dapat mempengaruhi kinerja model, terutama dalam hal akurasi prediksi untuk kelas minoritas.

3. Studi Kasus

Dalam studi kasus ini, kita akan mengimplementasikan teknik SMOTE (Synthetic Minority Over-sampling Technique) untuk mengatasi ketidakseimbangan kelas dalam dataset yang memiliki kelas minoritas dengan hanya 50 sampel negatif. Dataset ini memiliki ketidakseimbangan yang signifikan, dengan jumlah sampel kelas mayoritas yang jauh lebih banyak dibandingkan kelas minoritas. Dengan menggunakan `imblearn.over_sampling.SMOTE`, jumlah sampel negatif yang sebelumnya hanya 50 akan ditingkatkan menjadi 800 sampel sintetis. Proses ini dilakukan melalui interpolasi antara sampel minoritas yang ada dan tetangga terdekatnya, menghasilkan data baru yang lebih representatif untuk kelas negatif.

Hasilnya, distribusi kelas menjadi lebih seimbang, memungkinkan model klasifikasi untuk lebih efektif

mengenali pola dalam kelas negatif. Hal ini penting, terutama dalam kasus seperti analisis sentimen atau deteksi penipuan, di mana kelas negatif sering kali lebih jarang namun sangat penting untuk analisis yang tepat dan akurat.

Kode Pyhton

```
1 # Mengimpor pustaka yang diperlukan
2 from imblearn.over_sampling import SMOTE
3 from sklearn.model_selection import train_test_split
4 from collections import Counter
5 import numpy as np
6 # Misalkan X dan y adalah fitur dan label dataset yang tidak seimbang
7 # X = fitur dataset, y = label yang tidak seimbang
8 # Misalkan kita memiliki dataset di mana kelas minoritas (negatif) hanya memiliki 50 sampel
9 X = np.random.randn(550, 10) # 550 sampel dengan 10 fitur
10 y = np.array([0]*500 + [1]*50) # 500 sampel kelas mayoritas (0) dan 50 sampel kelas minoritas (1)
11
12 # Membagi data menjadi data pelatihan dan pengujian
13 X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.25, random_state=42)
14 # Menampilkan distribusi kelas sebelum SMOTE
15 print("Distribusi kelas sebelum SMOTE:", Counter(y_train))
16 # Inisialisasi SMOTE
17 smote = SMOTE (sampling_strategy=0.8, random_state=42)
18 #sampling_strategy=0.8 berarti jumlah kelas minoritas akan menjadi 800
19 # Terapkan SMOTE pada data pelatihan
20 X_res, y_res = smote.fit_resample(X_train, y_train)
21 # Menampilkan distribusi kelas setelah SMOTE
22 print("Distribusi kelas setelah SMOTE:", Counter(y_res))
23 # Cek dimensi data sebelum dan sesudah SMOTE
24 print ("Dimensi data sebelum SMOTE:", X_train.shape)
25 print("Dimensi data setelah SMOTE:", X_res.shape)
```

Output Program

```
Distribusi kelas sebelum SMOTE: Counter({0: 382, 1: 30})
Distribusi kelas setelah SMOTE: Counter({0: 382, 1: 305})
Dimensi data sebelum SMOTE: (412, 10)
Dimensi data setelah SMOTE: (687, 10)
```

Output ini menunjukkan perubahan distribusi kelas dan dimensi data sebelum dan setelah penerapan SMOTE (Synthetic Minority Over-sampling Technique). Sebelum SMOTE, kelas 0 memiliki 382 sampel dan kelas 1 hanya 30 sampel, menandakan ketidakseimbangan kelas yang sangat besar. Setelah SMOTE diterapkan, jumlah sampel untuk kelas 1 meningkat menjadi 305, mendekati kelas 0, menciptakan keseimbangan kelas. Dimensi data sebelum SMOTE adalah (412, 10), yang menunjukkan 412 sampel dengan 10 fitur. Setelah SMOTE, dimensi data menjadi (687, 10), menunjukkan bahwa jumlah sampel telah meningkat dengan menghasilkan sampel sintetis untuk kelas minoritas.

4. Soal Latihan

- 1) Jelaskan prinsip dasar dari teknik SMOTE dan bagaimana interpolasi antara sampel minoritas dilakukan untuk menghasilkan sampel sintetis baru. Sertakan penjelasan rumus yang digunakan dalam proses interpolasi.
- 2) Apa perbedaan utama antara teknik SMOTE dan teknik resampling lainnya seperti undersampling? Diskusikan kelebihan dan kekurangan masing-masing dalam konteks ketidakseimbangan kelas.

- 3) Bagaimana penerapan SMOTE dapat meningkatkan kinerja model klasifikasi dalam hal akurasi, recall, dan F1-score? Berikan contoh penerapannya di dunia nyata, seperti dalam analisis sentimen atau deteksi penipuan.
- 4) Apa saja tantangan yang dapat dihadapi saat menggunakan SMOTE, seperti risiko overfitting atau masalah dengan noise dan outliers dalam data? Bagaimana cara mengatasi tantangan tersebut?
- 5) Jelaskan bagaimana implementasi SMOTE menggunakan pustaka imblearn dapat meningkatkan distribusi kelas dalam dataset yang tidak seimbang. Apa pengaruh pengaturan parameter `sampling_strategy` terhadap jumlah sampel yang dihasilkan?

Daftar Pustaka

Gøttcke, J., & Zimek, A. (2021). Handling class imbalance in k-nearest neighbor classification by balancing prior probabilities. *Proceedings of the International Conference on Machine Learning*, 247-261. https://doi.org/10.1007/978-3-030-89657-7_19

Teknik Hybrid Resampling (SMOTEENN)

1. Konsep Dasar

Ketidakseimbangan kelas, masalah umum dalam pembelajaran mesin, terjadi saat satu kelas mendominasi dataset secara signifikan. Hal ini menyebabkan model menjadi bias terhadap kelas mayoritas dan mengabaikan kelas minoritas yang seringkali justru lebih kritis, seperti dalam deteksi penipuan, diagnosis medis, atau analisis sentimen (Kong et al., 2020; He & Yu, 2022). Algoritma tradisional, yang mengasumsikan distribusi kelas seimbang untuk kinerja optimal, cenderung memprediksi kelas mayoritas sehingga performa pada kelas minoritas sangat buruk (Wang et al., 2023; Yang et al., 2023). Akibatnya, meski akurasi model mungkin tinggi, metrik seperti recall atau F1-score untuk kelas minoritas menjadi rendah. Selain itu, ketidakseimbangan ini meningkatkan risiko overfitting, di mana model menghafal pola kelas mayoritas dan gagal menggeneralisasi fitur penting kelas minoritas.

Tantangan dalam Menghadapi Ketidakseimbangan Kelas

Tantangan utama ketidakseimbangan kelas adalah kecenderungan model pembelajaran mesin untuk overfit pada kelas mayoritas, sehingga mengabaikan ciri unik kelas minoritas dan menghasilkan prediksi buruk padahal kelas ini krusial dalam aplikasi dunia nyata (Kong et al., 2020). Algoritma tradisional, yang dirancang untuk dataset seimbang, menjadi tidak efektif karena model dapat mencapai akurasi tinggi hanya dengan memprediksi kelas mayoritas, sementara performa untuk kelas minoritas tetap rendah (Wang et al., 2023; Yang et al., 2023). Akibatnya, diperlukan teknik khusus untuk mengatasi bias ini agar prediksi pada kelas minoritas lebih akurat dan andal.

Teknik Resampling untuk Mengatasi Ketidakseimbangan Kelas

Resampling mengatasi ketidakseimbangan kelas dengan menyesuaikan distribusi data melalui over-sampling (menambah sampel minoritas) atau under-sampling (mengurangi sampel mayoritas). Namun, over-sampling konvensional berisiko *overfitting* jika hanya menggandakan data, sementara under-sampling berpotensi menghilangkan informasi berharga. SMOTE (Synthetic Minority Over-sampling Technique) mengatasi keterbatasan ini dengan menghasilkan sampel sintetis baru di antara titik data minoritas (Yang et al., 2023; Shah &

Passi, 2021). Meski efektif, SMOTE dapat menciptakan *noise* dekat batas keputusan yang menyulitkan klasifikasi. Oleh karena itu, pendekatan hibrid yang menggabungkan kedua teknik seringkali lebih optimal untuk menyeimbangkan representasi kelas tanpa mengorbankan informasi kritis.

SMOTE (Synthetic Minority Over-sampling Technique)

SMOTE (Synthetic Minority Over-sampling Technique) adalah teknik populer untuk mengatasi ketidakseimbangan kelas dengan **menghasilkan sampel sintetis** baru melalui interpolasi antar-data minoritas. Caranya: memilih sampel acak, mencari tetangga terdekatnya, lalu membuat titik data baru di sepanjang garis penghubungnya (Shah & Passi, 2021). Keunggulannya terletak pada **peningkatan keragaman data** yang mengurangi overfitting dan memperkaya representasi kelas minoritas. Namun, kelemahan utamanya adalah risiko menghasilkan sampel tidak representatif yang terlalu mirip dengan data asli atau malah menjadi *noise*—terutama di dekat batas keputusan—sehingga menyulitkan model memisahkan kelas secara akurat (Bazargani & Namee, 2020). Oleh karena itu, diperlukan teknik tambahan untuk menyaring sampel sintetis yang tidak relevan.

Edited Nearest Neighbors (ENN) untuk Pembersihan Data

Untuk mengatasi kelemahan SMOTE, teknik Edited Nearest Neighbors (ENN) digunakan sebagai metode pembersihan data. ENN mengidentifikasi dan menghapus sampel yang salah diklasifikasikan oleh mayoritas tetangga terdekatnya. Proses ini bertujuan menghilangkan data ambigu yang terletak di area tumpang tindih antar kelas, sehingga menghasilkan dataset yang lebih jelas dan representatif (Shah & Passi, 2021). Biasanya diaplikasikan *setelah* oversampling SMOTE, ENN berfungsi sebagai tahap pembersihan dengan membuang data yang tidak signifikan terhadap pola pembelajaran model. Dengan demikian, ENN meningkatkan kualitas dataset dengan memastikan hanya sampel yang relevan dan informatif yang digunakan untuk pelatihan, yang pada akhirnya membantu model belajar lebih efektif dan meningkatkan kinerja klasifikasi, terutama untuk kelas minoritas.

Menggabungkan SMOTE dan ENN: SMOTEENN

SMOTEENN, kombinasi teknik SMOTE dan ENN, merupakan cara ampuh mengatasi ketidakseimbangan kelas dalam data. SMOTE menambah sampel sintetis untuk kelas minoritas, sedangkan ENN membersihkan sampel ambigu yang berpotensi mengganggu klasifikasi. Sinergi

keduanya tidak hanya meningkatkan representasi kelas minoritas tetapi juga menjaga kualitas data latih yang tinggi. Hasilnya, model pembelajaran mesin menjadi lebih mampu mengenali pola kelas yang kurang terwakili. Dalam berbagai skenario penting, seperti deteksi penipuan atau diagnosis medis (Rimmer et al., 2022), pendekatan ini terbukti meningkatkan akurasi dan recall secara signifikan, menghasilkan model yang lebih andal dan adil.

Keuntungan dan Aplikasi SMOTEENN

SMOTEENN sangat bermanfaat dalam situasi di mana dataset menunjukkan ketidakseimbangan kelas yang signifikan, seperti dalam deteksi penipuan, diagnosis medis, dan analisis sentimen. Dalam aplikasi-aplikasi ini, kelas minoritas sering kali berisi informasi yang sangat penting yang dapat mempengaruhi hasil prediksi model. Dengan menggunakan SMOTEENN, kita dapat meningkatkan akurasi prediksi model, khususnya untuk kelas minoritas, yang biasanya kurang terwakili dalam dataset yang tidak seimbang.

Namun, SMOTEENN juga memiliki keterbatasan. Dalam dataset yang sangat bising atau jika kelas minoritas sangat sedikit, SMOTEENN mungkin tidak memberikan solusi yang paling efektif. Dalam kasus seperti ini, pendekatan lain seperti teknik ensemble hibrid atau

pembelajaran sensitif biaya mungkin diperlukan untuk menyesuaikan pendekatan dengan karakteristik dataset yang lebih spesifik (Parhizkari, 2024; Chen et al., 2024). Meskipun demikian, untuk kebanyakan kasus ketidakseimbangan kelas moderat, SMOTEENN terbukti menjadi alat yang sangat efektif.

2. Aplikasi

SMOTEENN merupakan pendekatan resampling yang dirancang untuk mengatasi ketidakseimbangan distribusi kelas dalam data klasifikasi, dengan menggabungkan dua teknik yaitu SMOTE (Synthetic Minority Over-sampling Technique) dan ENN (Edited Nearest Neighbor). SMOTE berperan dalam memperkuat representasi kelas minoritas dengan cara menciptakan sampel sintetis baru yang berbasis interpolasi antar tetangga terdekat dalam kelas tersebut. Sementara itu, ENN bertugas melakukan pembersihan pada data dengan menghapus sampel yang posisinya dianggap ambigu atau salah klasifikasi berdasarkan kedekatan dengan tetangga terdekat. Ketika kedua pendekatan ini digabungkan, hasilnya adalah dataset yang tidak hanya lebih seimbang secara kuantitatif, tetapi juga lebih bersih secara kualitas distribusi, yang pada

akhirnya memberikan dukungan signifikan terhadap peningkatan akurasi dan kestabilan model klasifikasi.

Kode Pyhton

```
1 from imblearn.combine import SMOTEENN
2 from sklearn.datasets import load_iris
3 from collections import Counter
4 import numpy as np
5 import pandas as pd
6 # Memuat dataset iris
7 data = load_iris()
8 X, y = data.data, data.target
9 # Membuat dataset tidak seimbang secara manual
10 # Hanya ambil sebagian data dari kelas 1 dan 2
11 X_0 = X[y == 0]
12 X_1 = X[y == 1][:30]
13 X_2 = X[y == 2][:20]
14 y_0 = y[y == 0]
15 y_1 = y[y == 1][:30]
16 y_2 = y[y == 2][:20]
17 # Gabungkan data kembali
18 X_imb = np.vstack((X_0, X_1, X_2))
19 y_imb = np.hstack((y_0, y_1, y_2))
20 # Cek distribusi sebelum resampling
21 print("Distribusi kelas sebelum resampling:", Counter(y_imb))
22 # Terapkan SMOTEENN
23 smoteenn = SMOTEENN(random_state=42)
24 X_resampled, y_resampled = smoteenn.fit_resample(X_imb, y_imb)
25 # Cek distribusi setelah resampling
26 print("Distribusi kelas setelah resampling:", Counter(y_resampled))
27 # Cek dimensi data
28 print("Dimensi data sebelum SMOTEENN:", X_imb.shape)
29 print("Dimensi data setelah SMOTEENN:", X_resampled.shape)
```

Output Program

```
Distribusi kelas sebelum resampling: Counter({0: 50, 1: 30, 2: 20})
Distribusi kelas setelah resampling: Counter({0: 50, 2: 48, 1: 46})
Dimensi data sebelum SMOTEENN: (100, 4)
Dimensi data setelah SMOTEENN: (144, 4)
```

Output program menunjukkan perubahan distribusi kelas dan ukuran dataset setelah penerapan teknik SMOTEENN. Sebelum resampling, dataset memiliki

ketidakseimbangan kelas: kelas 0 sebanyak 50 sampel, kelas 1 sebanyak 30, dan kelas 2 hanya 20. Setelah SMOTEENN diterapkan, jumlah sampel meningkat menjadi lebih seimbang: kelas 0 tetap 50, kelas 1 menjadi 46, dan kelas 2 menjadi 48. Ini menunjukkan bahwa SMOTE berhasil menambah data sintetis untuk kelas minoritas (1 dan 2), sementara ENN membersihkan sampel yang ambigu. Dimensi data berubah dari 100 baris menjadi 144 baris, menunjukkan peningkatan jumlah total sampel dengan tetap mempertahankan 4 fitur.

3. Studi Kasus

Distribusi kelas yang tidak seimbang dalam dataset dapat menyebabkan masalah serius dalam pelatihan model pembelajaran mesin, terutama ketika kelas minoritas memiliki peran penting dalam prediksi. Oleh karena itu, penting untuk menganalisis perbedaan distribusi kelas sebelum dan setelah penerapan teknik resampling seperti SMOTEENN. Pada Gambar 4, distribusi kelas sebelum penerapan SMOTEENN menunjukkan ketidakseimbangan yang jelas, di mana kelas mayoritas memiliki jumlah data yang jauh lebih banyak dibandingkan kelas minoritas.

Namun, setelah penerapan SMOTEENN, distribusi kelas menjadi lebih seimbang, dengan jumlah data kelas

minoritas yang kini lebih banyak berkat teknik SMOTE untuk oversampling dan ENN untuk pembersihan data. Hal ini memungkinkan model untuk mempelajari pola-pola dari kelas minoritas dengan lebih efektif, meningkatkan akurasi prediksi pada kelas tersebut tanpa mengabaikan kelas mayoritas. Dengan memvisualisasikan perubahan distribusi kelas ini, kita dapat mengukur keberhasilan teknik SMOTEENN dalam menangani masalah ketidakseimbangan kelas

4. Soal Latihan

- 1) jelaskan apa yang dimaksud dengan ketidakseimbangan kelas dalam dataset, dan bagaimana hal tersebut dapat mempengaruhi kinerja model pembelajaran mesin. Berikan contoh aplikasi di dunia nyata di mana ketidakseimbangan kelas menjadi masalah utama.
- 2) Sebutkan dan jelaskan dua teknik resampling utama yang digunakan untuk mengatasi ketidakseimbangan kelas. Apa kelebihan dan kekurangan masing-masing teknik tersebut?
- 3) Bagaimana teknik SMOTE bekerja untuk meningkatkan jumlah sampel pada kelas minoritas, dan apa saja tantangan yang dapat muncul ketika menggunakan SMOTE pada dataset yang sangat tidak seimbang?

- 4) Apa itu Edited Nearest Neighbors (ENN) dan bagaimana ENN dapat memperbaiki kualitas dataset yang telah disampling menggunakan SMOTE? Jelaskan proses bagaimana ENN membersihkan data yang ambigu atau salah klasifikasi.
- 5) SMOTEENN adalah kombinasi dari SMOTE dan ENN. Jelaskan bagaimana penggabungan kedua teknik ini memberikan solusi yang lebih baik dalam menangani ketidakseimbangan kelas dibandingkan dengan menggunakan SMOTE atau ENN secara terpisah. Apa saja aplikasi praktis yang dapat memanfaatkan SMOTEENN untuk meningkatkan akurasi model?

Daftar Pustaka

- Bazargani, M., & Namee, B. (2020). The elliptical basis function data descriptor (EBFDD) network: A one-class classification approach to anomaly detection. *Lecture Notes in Computer Science*, 107-123. https://doi.org/10.1007/978-3-030-46150-8_7
- Chen, W., Liu, C., Yu, W., Wen, J., & Lihua, Z. (2024). Asymmetric loss-oriented cost sensitive learning model for credit risk assessment. <https://doi.org/10.3233/atde231133>
- He, Q., & Yu, H. (2022). Optimal decision threshold-moving strategy for skewed Gaussian Naive Bayes classifier. *Proceedings of the International Conference on Data Science*, 837-843. https://doi.org/10.1007/978-981-19-2456-9_85
- Hendrickx, K., Meert, W., Cornelis, B., & Davis, J. (2022). Know your limits: Machine learning with rejection

- for vehicle engineering. *Lecture Notes in Computer Science*, 273-288. https://doi.org/10.1007/978-3-030-95405-5_20
- Kong, J., Kowalczyk, W., Menzel, S., & Bäck, T. (2020). Improving imbalanced classification by anomaly detection. *Proceedings of the International Conference on Machine Learning*, 512-523. https://doi.org/10.1007/978-3-030-58112-1_35
- Kulkarni, A., Chong, D., & Batarseh, F. (2020). Foundations of data imbalance and solutions for a data democracy. *Elsevier*, 83-106. <https://doi.org/10.1016/b978-0-12-818366-3.00005-8>
- Liang, H., Zhan, Z., Liu, W., Zhang, X., Tan, C., & Chen, X. (2024). Fedrema: Improving personalized federated learning via leveraging the most relevant clients. <https://doi.org/10.3233/faia240727>
- Parhizkari, S. (2024). Anomaly detection in intrusion detection systems. <https://doi.org/10.5772/intechopen.112733>
- Rimmer, V., Nadeem, A., Verwer, S., Preuveneers, D., & Joosen, W. (2022). Open-world network intrusion detection. *Lecture Notes in Computer Science*, 254-283. https://doi.org/10.1007/978-3-030-98795-4_11

Model Naive Bayes

1. Konsep Dasar

Model Naive Bayes, salah satu metode *machine learning* paling populer untuk klasifikasi, menggunakan pendekatan probabilistik berbasis Teorema Bayes untuk menghubungkan probabilitas bersyarat antar fitur. Meskipun model ini mengandalkan asumsi independensi fitur (setiap fitur diasumsikan tidak saling mempengaruhi), yang seringkali tidak realistis dalam data dunia nyata, kinerjanya tetap kuat secara empiris, terutama dalam pengolahan teks seperti analisis sentimen. Popularitasnya berasal dari kesederhanaan, efisiensi komputasi, dan keefektifannya yang konsisten dalam berbagai tugas klasifikasi teks, menjadikannya pilihan utama meski asumsi dasarnya jarang sepenuhnya terpenuhi.

Teorema Bayes dan Aplikasinya

Teorema Bayes merupakan inti dari model Naive Bayes. Teorema ini menghubungkan probabilitas suatu hipotesis (H) yang diberikan data (D) dengan probabilitas data yang diberikan hipotesis tersebut.

$$P(H|D) = \frac{P(D|H) \cdot P(H)}{P(D)}$$

Teorema ini memberikan cara untuk menghitung seberapa besar kemungkinan suatu kategori atau kelas (H) berdasarkan data yang diberikan (D). Dalam konteks analisis sentimen, misalnya, HHH bisa jadi kategori "positif" atau "negatif", dan DDD adalah ulasan produk yang diberikan. Teorema Bayes memungkinkan kita untuk menghitung probabilitas suatu kelas berdasarkan fitur-fitur yang diamati dalam data, menjadikannya alat yang sangat berguna dalam tugas klasifikasi.

Asumsi Independen Fitur

Salah satu asumsi utama dalam model Naive Bayes adalah independensi fitur, yaitu model ini menganggap bahwa semua fitur dalam dataset berkontribusi terhadap keputusan klasifikasi secara terpisah tanpa saling mempengaruhi satu sama lain. Dengan kata lain, meskipun dalam kenyataannya fitur-fitur ini sering saling bergantung, model ini menganggap bahwa keberadaan satu fitur dalam data tidak mempengaruhi keberadaan fitur lainnya. Matematis, model Naive Bayes dapat dinyatakan dengan persamaan berikut:

$$P(C_k|X_1, X_2, \dots, X_n) = \frac{P(C_k) \cdot \prod_{i=1}^n P(X_i|C_k)}{P(X_1, X_2, \dots, X_n)}$$

Dengan asumsi independensi fitur ini, perhitungan probabilitas menjadi jauh lebih sederhana dan efisien. Namun, hal ini juga dapat menjadi kelemahan model, karena dalam kenyataannya, fitur-fitur dalam dataset sering kali saling bergantung, yang dapat mempengaruhi kinerja model.

Implikasi dari Asumsi Independen Fitur

Meskipun asumsi independensi fitur pada Naive Bayes menyederhanakan perhitungan dan meningkatkan efisiensi, asumsi ini dapat mengurangi akurasi ketika fitur-fitur dalam data berkorelasi kuat—seperti kombinasi kata "sangat baik" atau "tidak puas" dalam analisis sentimen, di mana ketergantungan antar kata penting untuk makna. Asumsi ini mengabaikan hubungan tersebut, berpotensi melemahkan performa pada data dengan dependensi kompleks. Namun, Naive Bayes tetap efektif dalam banyak kasus dunia nyata, terutama ketika korelasi fitur lemah atau data bising. Sebagaimana dikonfirmasi Chen & Zhu (2023), model ini sering menghasilkan performa memadai meski dengan asumsi penyederhanaan, menjadikannya solusi praktis dan tangguh.

Kelebihan dari Naive Bayes

Model Naive Bayes menawarkan beberapa keuntungan utama yang membuatnya populer, terutama untuk tugas seperti klasifikasi teks dan analisis sentimen. Keunggulannya termasuk kecepatan dan efisiensi komputasi yang tinggi karena asumsi independensi antar fitur, memungkinkan pemrosesan dataset besar dengan cepat. Model ini juga mampu menangani ketidakseimbangan kelas dengan baik, seperti situasi dimana ulasan positif lebih banyak daripada ulasan negatif dalam analisis sentimen. Selain itu, Naive Bayes sederhana dan mudah diimplementasikan tanpa memerlukan banyak penyesuaian parameter. Terakhir, model ini cukup robust terhadap fitur yang tidak relevan karena asumsi independensinya membuat fitur-fitur tersebut memiliki dampak minimal pada hasil klasifikasi akhir.

Kelemahan dari Naive Bayes

Meskipun Naive Bayes menawarkan kelebihan seperti kesederhanaan dan efisiensi, model ini memiliki beberapa kelemahan penting. Pertama, asumsi independensi antar fitur (asumsi independen) sering kali tidak realistis di dunia nyata, di mana fitur-fitur biasanya saling terkait. Ketergantungan yang tidak tertangkap ini dapat mengurangi akurasi prediksi model secara

signifikan. Kedua, Naive Bayes kurang ideal untuk menangani data kontinu secara langsung. Meskipun dapat diadaptasi menggunakan teknik seperti distribusi Gaussian, pendekatan ini umumnya kurang efisien dibandingkan model yang secara inheren dirancang untuk data numerik, seperti Support Vector Machines (SVM) atau pohon keputusan. Terakhir, kesederhanaannya menjadi bumerang untuk hubungan kompleks. Naive Bayes sering gagal menangkap pola rumit antar fitur yang dapat dimodelkan lebih baik oleh algoritma lain seperti pohon keputusan, jaringan saraf tiruan (deep learning), atau ensemble methods. Akibatnya, kinerjanya bisa kalah pada masalah dengan interaksi fitur yang tinggi.

Aplikasi Praktis Naive Bayes dalam Analisis Sentimen

Naive Bayes banyak digunakan dalam analisis sentimen untuk mengklasifikasikan teks (seperti ulasan produk atau komentar media sosial) ke dalam kategori sentimen positif, negatif, atau netral. Popularitasnya terutama disebabkan oleh kemampuannya menangani data berskala besar dan teks berdimensi tinggi secara efisien, serta kemudahan implementasinya. Seperti dinyatakan Handhita & Wilujeng (2023), model ini bekerja baik pada data teks dengan fitur yang sangat banyak. Meskipun

mengasumsikan independensi antar fitur (kata), Naive Bayes sering memberikan kinerja praktis yang baik dan cepat. Setiawan et al. (2022) menekankan keunggulannya dalam aplikasi real-time yang membutuhkan kecepatan tinggi, seperti analisis umpan balik pelanggan.

2. Aplikasi

Pada tahap ini, kita akan membahas bagaimana melakukan pelatihan model Naive Bayes menggunakan implementasi `MultinomialNB` dari pustaka `sklearn.naive_bayes`. Model Multinomial Naive Bayes adalah varian dari Naive Bayes yang sangat cocok untuk data kategori, seperti teks, di mana fitur-fitur adalah frekuensi atau jumlah kemunculan kata dalam suatu dokumen.

Untuk memulai pelatihan model, kita perlu mempersiapkan data yang akan digunakan. Data tersebut harus dibagi menjadi dua bagian: data pelatihan (training data) dan data pengujian (test data). Dalam implementasinya, kita menggunakan `train_test_split` untuk membagi data secara acak. Setelah itu, kita dapat menggunakan `MultinomialNB()` dari `sklearn` untuk membangun model, diikuti dengan metode `fit()` untuk melatih model pada data pelatihan.

Pelatihan dilakukan dengan memberikan data yang sudah diproses melalui ekstraksi fitur, seperti menggunakan teknik TF-IDF atau N-Gram. Setelah pelatihan, model dapat digunakan untuk memprediksi kelas pada data pengujian dan dievaluasi menggunakan berbagai metrik seperti akurasi dan skor F1

3. Studi Kasus

Dalam kasus analisis sentimen, salah satu tantangan utama adalah bagaimana model dapat menangani ketidakseimbangan kelas, terutama pada kelas yang memiliki jumlah sampel lebih sedikit, seperti kelas negatif. Pada model Naive Bayes yang diterapkan dalam analisis sentimen, masalah ini sering kali terdeteksi dalam bentuk kinerja yang buruk pada kelas negatif, yang tercermin dari nilai precision yang sangat rendah, seperti 0.17 dalam contoh ini.

Precision mengukur seberapa banyak prediksi positif yang benar-benar merupakan kasus positif. Dalam hal ini, precision yang rendah pada kelas negatif menunjukkan bahwa meskipun model memprediksi banyak ulasan sebagai negatif, sebagian besar dari prediksi tersebut salah, yaitu mereka seharusnya lebih banyak dikategorikan sebagai positif atau netral. Hal ini mengarah pada

misclassifications yang signifikan, di mana sentimen negatif yang sebenarnya terabaikan atau disalahklasifikasikan.

Ada beberapa faktor yang dapat menyebabkan kinerja buruk pada kelas negatif. Salah satunya adalah ketidakseimbangan kelas dalam dataset, yang mana kelas positif sering kali mendominasi, sementara kelas negatif memiliki lebih sedikit contoh untuk dipelajari. Ini membuat model cenderung lebih sensitif terhadap kelas mayoritas, yang dalam hal ini adalah kelas positif. Selain itu, asumsi independensi fitur dalam Naive Bayes juga berperan, karena seringkali kata-kata yang mengindikasikan sentimen negatif tidak diidentifikasi secara efektif jika fitur-fitur tersebut terkait erat.

Penerapan teknik seperti SMOTE atau SMOTEENN untuk mengatasi ketidakseimbangan kelas dapat membantu meningkatkan kinerja pada kelas negatif. Dengan menyeimbangkan jumlah sampel antara kelas positif dan negatif, model dapat belajar untuk mengenali sentimen negatif dengan lebih akurat, meningkatkan precision dan recall pada kelas tersebut

4. Soal Latihan

- 1) Jelaskan secara rinci bagaimana Teorema Bayes digunakan dalam model Naive Bayes dan apa peran pentingnya dalam proses klasifikasi teks?
- 2) Apa yang dimaksud dengan asumsi independensi fitur dalam model Naive Bayes? Jelaskan bagaimana asumsi ini dapat mempengaruhi kinerja model, terutama pada dataset dengan fitur yang saling bergantung.
- 3) Analisislah alasan mengapa model Naive Bayes sering memberikan hasil yang buruk pada kelas negatif dalam analisis sentimen, terutama ketika precision kelas negatif rendah. Apa faktor-faktor yang mempengaruhi kinerja buruk ini dan bagaimana cara mengatasinya?
- 4) Berdasarkan pembahasan tentang kelebihan dan kekurangan Naive Bayes, bagaimana model ini tetap efektif dalam klasifikasi teks meskipun asumsi independensi fitur sering kali tidak realistis? Berikan contoh situasi di mana Naive Bayes masih lebih unggul dibandingkan model lain.
- 5) Bagaimana cara meningkatkan akurasi model Naive Bayes dalam kasus analisis sentimen dengan dataset yang tidak seimbang? Jelaskan beberapa teknik yang dapat digunakan untuk menyeimbangkan dataset dan meningkatkan kinerja model pada kelas minoritas.

Daftar Pustaka

- Chen, H., & Zhu, Y. (2023). Improved TF-IDF-based LDA topic clustering model for specific commodity contexts and different sentiment tendencies. *Frontiers in Artificial Intelligence and Applications*, 230934.
- Handhita, S., & Wilujeng, I. (2023). The role of e-trust as a mediating variable on predicting the effect of website design quality and online reviews on online booking intention. *Proceedings of the International Conference on Business and Technology*, 252–263.
- Sagvekar, V., & Sharma, P. (2021). Study on product opinion analysis for customer satisfaction on e-commerce websites. *Advances in Parallel Computing*, 210206.
- Setiawan, I., Widodo, A., Rahaman, M., Tugiman, T., Hadi, M., Anwar, N., ... Erzed, N. (2022). Utilizing random forest algorithm for sentiment prediction based on Twitter data. *Proceedings of the International Conference on Data Science and Machine Learning*, 446–456.

Model Support Vector Machine (SVM)

1. Konsep Dasar

Support Vector Machine (SVM) merupakan salah satu algoritma yang banyak digunakan dalam bidang *machine learning* untuk tugas klasifikasi dan regresi. Tujuan utama dari SVM adalah untuk menemukan hyperplane yang memisahkan data dalam ruang fitur sedemikian rupa sehingga jarak antar data dari kelas yang berbeda semakin besar. Konsep-konsep dasar seperti hyperplane, margin, support vector, dan kernel linear sangat penting untuk memahami cara kerja SVM dalam menyelesaikan masalah klasifikasi. Selain itu, pemahaman tentang kekuatan dan keterbatasan penggunaan kernel linear dalam SVM akan membantu dalam memilih kernel yang tepat untuk tugas yang diberikan.

Memahami Hyperplane

Hyperplane adalah permukaan datar berdimensi tinggi (m -dimensi, sesuai jumlah fitur) yang berfungsi sebagai pemisah antara dua kelompok data berbeda. Dalam Support Vector Machine (SVM), hyperplane inilah yang membagi data dari dua kelas dalam ruang berdimensi- n . Secara sederhana, pada data dua dimensi (seperti titik di

bidang datar), hyperplane muncul sebagai garis lurus pemisah. Untuk data yang lebih kompleks dan berdimensi lebih tinggi, bentuknya tak terlihat, namun konsepnya sama. Tujuan utama SVM adalah menemukan hyperplane optimal yang tidak hanya memisahkan kelas, tetapi juga memiliki margin (jarak terlebar) ke titik data terdekat dari masing-masing kelas. Memaksimalkan margin ini bertujuan agar model SVM lebih akurat dalam mengklasifikasikan data baru (Cortes & Vapnik, 1995)..

Konsep Margin

Dalam Support Vector Machine (SVM), margin adalah jarak antara bidang keputusan (hyperplane) dan titik data terdekat dari setiap kelas, yang disebut support vectors. Tujuan utama SVM adalah memaksimalkan margin ini, karena margin yang lebih besar meningkatkan kemampuan generalisasi model terhadap data baru, membuat klasifikasi lebih andal dan mengurangi risiko overfitting. Support vectors merupakan elemen kritis karena hanya merekalah yang menentukan posisi hyperplane; titik data lain tidak berpengaruh. Jika support vectors dihilangkan, batas keputusan berubah, sehingga akurasi model terdampak. Dengan kata lain, memaksimalkan margin melalui support vectors menghasilkan model yang lebih robust dan akurat untuk data tak terlihat (Cortes & Vapnik, 1995)

Kernel Linear dalam SVM

Salah satu fitur penting dalam SVM adalah Dalam SVM, fungsi kernel memungkinkan pemetaan data ke dimensi lebih tinggi untuk memisahkan data nonlinier. Kernel linear merupakan opsi dasar yang mengandalkan *inner product* antarvektor dalam ruang fitur asli, tanpa transformasi dimensi. Ia optimal untuk data yang secara inheren terpisah linier (dipisahkan oleh hyperplane lurus). Keunggulan utamanya adalah efisiensi komputasi, karena menghindari perhitungan ruang fitur dimensi tinggi yang kompleks. Kernel ini cocok untuk masalah klasifikasi dengan hubungan linier jelas antara input dan output, mempercepat pelatihan model sekaligus mempertahankan akurasi pada data yang memenuhi asumsi linearitas.

Kelebihan dan Kekurangan SVM Linear

SVM linear menawarkan efisiensi komputasi tinggi, terutama ideal untuk data berfitur sangat banyak (*high-dimensional*) seperti dalam klasifikasi teks (deteksi spam, analisis sentimen) dan bioinformatika, karena mampu menemukan pemisah linear (*hyperplane*) optimal dengan cepat ketika data terpisah jelas. Namun, pendekatan ini memiliki keterbatasan utama pada asumsi keterpisahan linear data. Jika hubungan antar kelas non-linear, kernel

linear menjadi kurang akurat dan kernel non-linear (seperti RBF atau polinomial) lebih disarankan. Selain itu, kinerjanya sensitif terhadap *noise* dan *outlier* karena fokus pada *support vectors* di dekat batas keputusan, sehingga praproses data untuk mengurangi gangguan ini sangat penting sebelum penerapan..

2. Aplikasi

Dalam implementasi Support Vector Machine (SVM) dengan pustaka scikit-learn, penyesuaian parameter `C` dan `class_weight` sangat menentukan performa klasifikasi, khususnya ketika bekerja dengan data yang tidak seimbang. Parameter `C` mengendalikan keseimbangan antara margin pemisah yang luas dan tingkat toleransi terhadap kesalahan klasifikasi; nilai yang terlalu kecil dapat menyebabkan model kurang kompleks, sedangkan nilai terlalu besar berisiko membuat model terlalu kaku terhadap data pelatihan. Di sisi lain, pengaturan `class_weight`, terutama dengan opsi 'balanced', memungkinkan distribusi bobot yang lebih adil antar kelas berdasarkan proporsi kemunculannya. Kombinasi keduanya menciptakan model yang tidak hanya akurat terhadap mayoritas, tetapi juga sensitif terhadap kelas minoritas, memperkuat keandalan hasil klasifikasi secara keseluruhan

3. Studi Kasus

Kode Python

```
1 # Mengimpor pustaka yang diperlukan
2 import numpy as np
3 import pandas as pd
4 from sklearn.svm import SVC
5 from sklearn.model_selection import train_test_split
6 from sklearn.metrics import classification_report, f1_score
7 from imblearn.over_sampling import SMOTE
8 from sklearn.datasets import make_classification
9 import matplotlib.pyplot as plt
10 # Membuat dataset sintetik yang tidak seimbang
11 X, y = make_classification(n_samples=1000, n_features=20, n_informative=2, n_redundant=10,
12                           n_classes=2, weights=[0.9, 0.1], flip_y=0, random_state=42)
13 # Membagi dataset menjadi data latih dan data uji
14 X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.25, random_state=42)
15 # Menerapkan SMOTE untuk menangani ketidakseimbangan kelas
16 smote = SMOTE(random_state=42)
17 X_res, y_res = smote.fit_resample(X_train, y_train)
18 # Melatih model SVM dengan kernel linear
19 svm_model = SVC(kernel='linear', class_weight='balanced', random_state=42)
20 svm_model.fit(X_res, y_res)
21 # Membuat prediksi pada data uji
22 y_pred = svm_model.predict(X_test)
23 # Menampilkan laporan klasifikasi dan F1-score
24 report = classification_report(y_test, y_pred)
25 f1_negative = f1_score(y_test, y_pred, pos_label=0) # F1-score untuk kelas negatif
26 # Menampilkan hasil
27 print ("F1-score untuk Kelas Negatif: ", f1_negative)
28 print ("Laporan Klasifikasi:\n", report)
29 # Opsional, plot confusion matrix (jika diinginkan)
30 from sklearn.metrics import confusion_matrix
31 import seaborn as sns
32 cm = confusion_matrix(y_test, y_pred)
33 sns.heatmap(cm, annot=True, fmt='d', cmap='Blues', xticklabels=['Kelas 0', 'Kelas 1'], yticklabels=['Kelas 0', 'Kelas 1'])
34 plt.xlabel('Prediksi')
35 plt.ylabel('Benar')
36 plt.title('Confusion Matrix')
37 plt.show()
```

Output Program


```

F1-score untuk Kelas Negatif: 0.9444444444444444
Laporan Klasifikasi:

```

	precision	recall	f1-score	support
0	0.98	0.91	0.94	224
1	0.52	0.85	0.65	26
accuracy			0.90	250
macro avg	0.75	0.88	0.80	250
weighted avg	0.93	0.90	0.91	250

Evaluasi performa model menunjukkan F1-score 0.94 untuk kelas negatif dan 0.65 untuk kelas positif, dengan precision 0.52 serta recall 0.85. Dari 100 sampel positif, 85 dikenali, namun 48 prediksi salah berasal dari kelas negatif. Nilai macro F1-score 0.80 menegaskan perlunya peningkatan keseimbangan klasifikasi.



Gambar di atas menunjukkan confusion matrix dari hasil klasifikasi dua kelas: kelas 0 (negatif) dan kelas 1 (positif). Terdapat 204 data kelas 0 yang diprediksi dengan

benar, dan 22 data kelas 1 yang juga diklasifikasikan dengan tepat. Namun, terdapat 20 data kelas 0 yang salah diklasifikasikan sebagai kelas 1 (false positive), dan 4 data kelas 1 yang salah diprediksi sebagai kelas 0 (false negative). Matriks ini menunjukkan bahwa model memiliki performa yang sangat baik dalam mengenali kelas 0, dengan sedikit kesalahan pada kelas 1. Secara keseluruhan, model menunjukkan keseimbangan antara akurasi dan recall yang cukup baik.

4. Soal Latihan

1. Apa yang dimaksud dengan hyperplane dalam model Support Vector Machine (SVM)? Bagaimana hyperplane berperan dalam memisahkan kelas-kelas dalam ruang fitur? Berikan contoh implementasi SVM dengan dataset dua dimensi untuk memperjelas konsep ini.
2. Jelaskan apa yang dimaksud dengan margin dalam konteks SVM. Bagaimana SVM berusaha untuk memaksimalkan margin antara dua kelas? Apa pengaruh besar margin terhadap kemampuan generalisasi model SVM?
3. Apa yang dimaksud dengan support vectors dalam model SVM? Bagaimana titik-titik ini mempengaruhi

posisi hyperplane? Mengapa support vectors sangat penting dalam model SVM?

4. Bagaimana kernel linear dalam SVM bekerja dalam menghitung pemisahan antara kelas-kelas? Jelaskan keuntungan menggunakan kernel linear dalam hal efisiensi komputasi dan kapan kernel linear lebih disarankan dibandingkan dengan kernel non-linear.
5. Bagaimana parameter *class_weight* dalam SVM membantu menangani ketidakseimbangan kelas? Jelaskan dengan memberikan contoh bagaimana pengaturan parameter ini dapat mempengaruhi hasil klasifikasi pada data dengan distribusi kelas yang tidak merata.

Daftar Pustaka

- Chen, H., & Zhu, Y. (2023). Improved TF-IDF-based LDA topic clustering model for specific commodity contexts and different sentiment tendencies. *Frontiers in Artificial Intelligence and Applications*, 230934. <https://doi.org/10.3233/faia230934>
- Gøttcke, J., & Zimek, A. (2021). Handling class imbalance in k-nearest neighbor classification by balancing prior probabilities. *Proceedings of the International Conference on Machine Learning*, 247–261. https://doi.org/10.1007/978-3-030-89657-7_19
- He, Q., & Yu, H. (2022). Optimal decision threshold-moving strategy for skewed Gaussian Naive Bayes classifier. *Proceedings of the International Conference on Artificial Intelligence*, 837–843. https://doi.org/10.1007/978-981-19-2456-9_85

- Mukherjee, S., Kasner, Z., & Dušek, O. (2022). Balancing the style-content trade-off in sentiment transfer using polarity-aware denoising. *Proceedings of the International Conference on Data Mining and Machine Learning*, 172–186.
https://doi.org/10.1007/978-3-031-16270-1_15
- Saxena, A., Jain, A., Sharma, P., Singla, S., & Ticku, A. (2023). Sentiment analysis of stocks based on news headlines using NLP. *Proceedings of the International Conference on Artificial Intelligence and Financial Engineering*, 124–135.
https://doi.org/10.2991/978-94-6463-074-9_12

Model Decision Tree

1. Konsep Dasar

Decision Tree adalah algoritma populer untuk klasifikasi dan regresi yang bekerja secara hierarkis dengan memecah data berdasarkan atribut, membentuk struktur pohon. Simpul mewakili keputusan atribut, cabang hasil keputusan, dan daun prediksi akhir. Proses pemecahan (*splitting*) berlanjut hingga data dalam cabang cukup homogen (Sindhu & Prakash, 2021). Tujuannya menemukan pola untuk memetakan data ke kategori/nilai target. Aspek krusialnya adalah *splitting* untuk meningkatkan homogenitas di setiap cabang, diukur menggunakan *impurity* (ketidakteraturan) seperti Gini impurity atau entropy. Metode ini memilih atribut pembagi yang paling signifikan mengurangi *impurity*, memisahkan data menjadi kelompok lebih seragam, sehingga meningkatkan akurasi prediksi (Makri et al., 2021).

Gini Impurity

Gini impurity mengukur sejauh mana distribusi kelas dalam suatu node tidak seimbang. Nilai Gini berkisar antara 0 hingga 1, dengan nilai 0 menunjukkan bahwa semua elemen dalam node tersebut berasal dari kelas yang sama,

dan nilai 1 menunjukkan bahwa elemen dalam node tersebut terdistribusi secara merata di antara semua kelas. Idealnya, dalam pembentukan decision tree, pembagian data dilakukan untuk meminimalkan nilai Gini impurity, dengan mencari atribut yang dapat menghasilkan pembagian dengan nilai Gini yang lebih rendah pada setiap cabang pohon. Formula perhitungan Gini impurity adalah sebagai berikut:

$$Gini(t) = 1 - \sum_{i=1}^k p_i^2$$

Entropy

Entropy, di sisi lain, adalah ukuran ketidakpastian atau keraguan dalam distribusi kelas di dalam node. Entropy lebih tinggi jika data terdistribusi secara merata di antara beberapa kelas, dan lebih rendah jika data terkonsentrasi pada satu kelas saja. Tujuan dari penggunaan entropy dalam decision tree adalah untuk mencari pemisahan yang mengurangi ketidakpastian dalam data, yang berarti pembagian data yang menghasilkan entropy yang lebih rendah (Baglat et al., 2020). Formula perhitungan entropy adalah sebagai berikut:

$$Entropy(t) = - \sum_{i=1}^k p_i \log_2(p_i)$$

Pruning untuk Menghindari Overfitting

Decision tree rentan terhadap overfitting, di mana model menjadi terlalu kompleks dan akurat pada data latih namun gagal menggeneralisasi ke data baru. Untuk mengatasi ini, teknik pruning digunakan untuk memangkas cabang yang tidak signifikan, mengurangi kompleksitas model dan meningkatkan kemampuan generalisasi (Sutton-Charani, 2020). Terdapat dua pendekatan utama: Pre-pruning menghentikan pembentukan pohon lebih awal dengan membatasi kedalaman maksimum, jumlah sampel minimum, atau ambang pengurangan ketidakteraturan (impurity), mencegah kompleksitas berlebihan namun berisiko memotong terlalu dini (Makri et al., 2021). Post-pruning, diterapkan setelah pohon terbangun penuh, memangkas cabang berdasarkan signifikansinya. Teknik seperti cost-complexity pruning menyeimbangkan ukuran pohon dan akurasi, umumnya lebih fleksibel dan efektif mengurangi overfitting dibanding pre-pruning (Lamrini, 2021).

2. Aplikasi

Salah satu tantangan utama dalam penggunaan model decision tree adalah overfitting, di mana model terlalu menyesuaikan diri dengan data pelatihan dan tidak dapat menggeneralisasi dengan baik pada data baru. Untuk mengatasi masalah ini, teknik pembatasan kedalaman pohon (max_depth) digunakan. Dengan menetapkan batas maksimum kedalaman pohon, model hanya dapat melakukan pemisahan data hingga tingkat tertentu, sehingga pohon tidak tumbuh terlalu kompleks. Pembatasan ini menjaga keseimbangan antara akurasi dan generalisasi, menghasilkan model yang lebih sederhana dan efisien. Sebagai hasilnya, model dapat melakukan prediksi dengan lebih andal pada data yang belum terlihat sebelumnya.

3. Studi Kasus

Pohon keputusan digunakan untuk klasifikasi sentimen dalam analisis teks dengan memisahkan ulasan berdasarkan atribut seperti kata-kata atau frasa. Setiap simpul mewakili keputusan berdasarkan atribut, dan cabang menunjukkan hasil yang mungkin. Interpretasi pohon penting untuk memahami faktor-faktor yang

mempengaruhi klasifikasi sentimen dan memastikan transparansi model (Zhang et al., 2023).

Kode Pyhton

```
1 # Importing necessary libraries
2 import pandas as pd
3 from sklearn.model_selection import train_test_split
4 from sklearn.feature_extraction.text import TfidfVectorizer
5 from sklearn.tree import DecisionTreeClassifier, export_text
6 from sklearn.metrics import classification_report, accuracy_score
7 # Sample data: Texts and corresponding sentiment labels (Positive, Negative)
8 data = {
9     'text': ['I love this product', 'This is the worst purchase I made', 'I am very happy with this',
10            'I will never buy this again', 'Fantastic quality, highly recommend', 'Not worth the money'],
11     'sentiment': ['Positive', 'Negative', 'Positive', 'Negative', 'Positive', 'Negative']
12 }
13 # Creating a DataFrame
14 df = pd.DataFrame(data)
15 # Splitting the data into features (X) and labels (y)
16 X = df['text']
17 y = df['sentiment']
18 # Converting text to numerical data using TF-IDF
19 vectorizer = TfidfVectorizer()
20 X_tfidf = vectorizer.fit_transform(X)
21 # Splitting the data into training and testing sets
22 X_train, X_test, y_train, y_test = train_test_split(X_tfidf, y, test_size=0.33, random_state=42)
23 # Initializing the Decision Tree Classifier
24 dt = DecisionTreeClassifier(max_depth=3, random_state=42)
25 # Training the model
26 dt.fit(X_train, y_train)
27 # Predicting on the test set
28 y_pred = dt.predict(X_test)
29 # Evaluating the model's performance
30 print("Accuracy:", accuracy_score(y_test, y_pred))
31 print("\nClassification Report:\n", classification_report(y_test, y_pred))
32 # Displaying the decision tree rules
33 tree_rules = export_text(dt, feature_names=vectorizer.get_feature_names_out())
34 print("\nDecision Tree Rules:\n", tree_rules)
```

Output Program

Accuracy: 0.5

Classification Report:				
	precision	recall	f1-score	support
Negative	0.00	0.00	0.00	1
Positive	0.50	1.00	0.67	1
accuracy			0.50	2
macro avg	0.25	0.50	0.33	2
weighted avg	0.25	0.50	0.33	2

Output menunjukkan akurasi model sebesar 50%, yang berarti hanya setengah dari prediksi yang benar. Pada classification report, terlihat bahwa model hanya berhasil mengenali kelas "Positive" dengan recall 1.00, tetapi precision-nya rendah (0.50), dan gagal total dalam mengenali kelas "Negative" (semua metrik bernilai 0). Nilai f1-score untuk kelas "Positive" adalah 0.67, sedangkan untuk "Negative" adalah 0.00. Nilai macro average f1-score sebesar 0.33 menunjukkan performa rata-rata antar kelas yang rendah, akibat ketidakseimbangan prediksi. Hasil ini mencerminkan kelemahan model dalam generalisasi dan kemungkinan disebabkan oleh jumlah data uji yang sangat sedikit (hanya 2 sampel).

```
Decision Tree Rules:
|--- again <= 0.24
|   |--- money <= 0.26
|   |   |--- class: Positive
|   |   |--- money > 0.26
|   |   |--- class: Negative
|--- again > 0.24
|   |--- class: Negative
```

Output tersebut menunjukkan aturan yang dibentuk oleh model Decision Tree dalam mengklasifikasikan sentimen berdasarkan nilai TF-IDF dari kata-kata dalam ulasan. Model menggunakan kata "again" dan "money" sebagai fitur penting untuk memisahkan data. Jika nilai TF-IDF untuk kata "again" kurang dari atau sama dengan 0.24, dan "money" juga kurang dari atau sama dengan 0.26, maka model memprediksi sentimen sebagai "Positive". Jika nilai "money" lebih dari 0.26, maka diklasifikasikan sebagai "Negative". Sementara itu, jika nilai "again" lebih dari 0.24, langsung dikategorikan sebagai "Negative". Tampilan ini menunjukkan bagaimana model memanfaatkan kata kunci untuk mengambil keputusan klasifikasi.

4. Soal Latihan

1. Jelaskan konsep dasar dari model Decision Tree! Bagaimana algoritma ini bekerja dalam menyelesaikan masalah klasifikasi dan regresi?

2. Apa yang dimaksud dengan impurity dalam konteks decision tree, dan bagaimana Gini Impurity dan Entropy digunakan untuk mengukur impurity? Jelaskan perbedaan antara keduanya.
3. Bagaimana pembatasan pada parameter max_depth dapat membantu menghindari overfitting dalam model decision tree? Jelaskan dengan contoh!
4. Dalam konteks klasifikasi sentimen, bagaimana pohon keputusan dapat diinterpretasikan untuk memahami keputusan yang diambil oleh model? Berikan contoh bagaimana aturan yang dihasilkan oleh pohon keputusan digunakan untuk menentukan sentimen sebuah teks.
5. Jelaskan perbedaan antara teknik pre-pruning dan post-pruning dalam decision tree. Kapan sebaiknya masing-masing teknik digunakan, dan apa dampaknya terhadap kinerja model?

Daftar Pustaka

- Baglat, P., Salehi, A., Gupta, A., & Gupta, G. (2020). Multiple machine learning models for detection of Alzheimer's disease using OASIS dataset. *In Proceedings of the 2020 International Conference on Computing, Communication, and Networking Technologies* (pp. 614-622). https://doi.org/10.1007/978-3-030-64849-7_54

- Lamrini, B. (2021). Contribution to decision tree induction with Python: A review. *IntechOpen*.
<https://doi.org/10.5772/intechopen.92438>
- Makri, E., Koskinas, I., Tsolakis, A., Ioannidis, D., & Tzovaras, D. (2021). Short term net imbalance volume forecasting through machine and deep learning: A UK case study. *In Proceedings of the 2021 International Conference on Artificial Intelligence and Data Science* (pp. 377-389).
https://doi.org/10.1007/978-3-030-79157-5_31
- Sindhu, V., & Prakash, M. (2021). Comparative analysis among decision tree vs. Naive Bayes for prediction of weather prognostication. *Advances in Parallel Computing*, 210206.
<https://doi.org/10.3233/apc210018>
- Sutton-Charani, N. (2020). Bayesian smoothing of decision tree soft predictions and evidential evaluation. *In Proceedings of the International Conference on Machine Learning* (pp. 368-381).
https://doi.org/10.1007/978-3-030-50143-3_28
- Zhang, H., Quost, B., & Masson, M. (2023). Cautious decision-making for tree ensembles. *In Advances in Decision Trees and Ensemble Methods* (pp. 3-14).
https://doi.org/10.1007/978-3-031-45608-4_1

Evaluasi Model

1. Konsep Dasar

Evaluasi model menjadi bagian fundamental dalam pengembangan sistem klasifikasi berbasis kecerdasan buatan, khususnya dalam aplikasi e-commerce yang dinamis dan berorientasi pada interaksi konsumen. Tujuan utama dari tahapan ini adalah memastikan bahwa hasil klasifikasi terhadap ekspresi sentimen, baik dalam bentuk positif, negatif, maupun netral, benar-benar mencerminkan realitas dari pengalaman pengguna sebagaimana tercermin melalui ulasan produk. Mengingat pentingnya ulasan dalam mempengaruhi keputusan konsumen lain, akurasi klasifikasi menjadi aspek penting yang harus diperhatikan. Oleh karena itu, pemanfaatan ukuran kuantitatif dan indikator performa menjadi landasan dalam mengukur kualitas prediksi, terlebih ketika menghadapi distribusi data yang tidak seimbang.. Tujuan utama dari proses ini adalah memastikan bahwa hasil klasifikasi terhadap sentimen, baik positif, negatif, maupun netral, dapat merepresentasikan realitas pengalaman pengguna secara akurat. Dalam kasus ulasan produk, representasi yang tepat sangat penting karena ulasan menjadi salah satu faktor kunci yang memengaruhi keputusan konsumen lain dalam melakukan

pembelian. Oleh karena itu, evaluasi kinerja model perlu dilakukan dengan menggunakan pendekatan kuantitatif dan metrik yang mencerminkan kualitas prediksi, terutama pada dataset yang tidak seimbang distribusinya.

Dalam ranah ini, beberapa metrik utama digunakan untuk menilai performa model secara objektif. Precision mengukur seberapa tepat prediksi model terhadap setiap kelas, khususnya berapa banyak dari prediksi positif yang benar-benar relevan. Recall, di sisi lain, memeriksa sejauh mana model mampu menangkap semua contoh dari suatu kelas. Ketika precision dan recall tidak seimbang, *F1-score* menjadi indikator yang menyeimbangkan keduanya dan memberikan gambaran yang lebih menyeluruh terhadap performa model, terutama saat ketidakseimbangan kelas menjadi kendala.

Ketika suatu dataset menunjukkan dominasi kelas tertentu—seperti kelas sentimen positif yang mendominasi ulasan e-commerce—penggunaan nilai rata-rata sederhana tidak lagi memberikan informasi representatif. Dalam kondisi seperti ini, dua pendekatan umum digunakan: macro average dan weighted average. Macro average menghitung metrik untuk setiap kelas dan kemudian merata-ratakannya tanpa mempertimbangkan ukuran masing-masing kelas. Ini memberikan bobot yang sama untuk semua kelas, yang penting dalam mengukur

performa pada kelas minoritas. Sementara itu, weighted average menghitung rata-rata dengan mempertimbangkan proporsi jumlah data dalam masing-masing kelas. Ini memungkinkan pemahaman yang lebih realistis terhadap performa keseluruhan, terutama ketika evaluasi diarahkan pada sistem produksi.

Model yang diuji dalam skenario e-commerce sering kali menghadapi distribusi ulasan yang berat sebelah, misalnya 80% positif dan sisanya terbagi antara netral dan negatif. Dalam situasi seperti ini, meskipun akurasi keseluruhan model bisa tinggi, hal tersebut bisa menyesatkan karena sebagian besar prediksi mungkin hanya tertuju pada kelas dominan. Maka, *F1-score* macro average menjadi ukuran yang lebih tepat untuk mengetahui apakah model mampu memahami dan mengklasifikasikan semua sentimen secara adil. Performa model yang seimbang menunjukkan bahwa sistem mampu menangkap variasi dalam ekspresi pengguna, termasuk keluhan halus maupun pujian eksplisit.

Sebagai contoh, ketika model memperoleh *F1-score* sebesar 0,94 untuk kelas negatif, berarti ia sangat efektif dalam mendeteksi ulasan dengan muatan ketidakpuasan. Namun, jika pada kelas positif hanya mencapai nilai *F1-score* sebesar 0,65, walau recall tinggi menunjukkan bahwa model banyak menemukan contoh kelas tersebut, precision

yang rendah mengindikasikan banyak prediksi salah sasaran. Hal ini menandakan bahwa model masih cenderung menebak secara luas tanpa presisi tinggi, yang bisa menjadi masalah ketika informasi yang ingin disampaikan kepada pengelola platform atau penjual memerlukan ketepatan.

Oleh karena itu, penggunaan confusion matrix juga sangat membantu dalam memahami distribusi kesalahan model. Matriks ini memberikan gambaran tentang prediksi yang benar dan salah dalam setiap kelas, sehingga pelaku bisnis atau pengembang dapat melihat pola kesalahan secara rinci. Dengan demikian, tindakan perbaikan, seperti penyesuaian parameter atau pemilihan fitur yang lebih relevan, dapat dilakukan dengan pendekatan berbasis data.

Di samping itu, adanya ketidakseimbangan kelas mendorong diterapkannya pendekatan khusus dalam tahap praproses data, misalnya dengan menerapkan teknik resampling. Salah satu pendekatan yang terbukti efektif adalah SMOTEENN, yaitu kombinasi dari Synthetic Minority Oversampling Technique (SMOTE) dan Edited Nearest Neighbour (ENN). SMOTE menciptakan contoh sintetis baru untuk kelas minoritas, sementara ENN menghapus sampel yang dekat dengan batas kelas yang membingungkan. Kombinasi ini menciptakan dataset yang lebih bersih dan

seimbang, yang kemudian meningkatkan performa model dalam pengklasifikasian semua kelas.

Evaluasi yang akurat juga membutuhkan pengaturan parameter yang optimal dalam model. Pada Support Vector Machine (SVM), misalnya, parameter `C` dan `class_weight` memegang peranan penting. `C` mengontrol tingkat toleransi kesalahan terhadap pelatihan, dengan nilai yang lebih tinggi membuat model fokus pada akurasi pelatihan, sedangkan `class_weight` berguna dalam menangani ketidakseimbangan kelas dengan memberi bobot lebih besar pada kelas minoritas. Penggunaan opsi 'balanced' memungkinkan sistem menyesuaikan bobot secara otomatis berdasarkan proporsi data. Dalam praktiknya, pengaturan parameter ini diuji melalui teknik validasi silang untuk mendapatkan konfigurasi terbaik yang memberikan performa stabil.

Dalam penggunaan nyata, evaluasi performa tidak hanya berhenti pada angka, tetapi juga menyangkut pemahaman dampak prediksi tersebut terhadap proses bisnis. Misalnya, kemampuan model dalam mengidentifikasi ulasan negatif secara akurat memungkinkan perusahaan menanggapi keluhan lebih cepat, menjaga reputasi, dan meningkatkan loyalitas konsumen. Sementara itu, pengenalan ulasan positif secara tepat membantu dalam memetakan kekuatan produk, mengarahkan strategi

promosi, dan mengidentifikasi aspek yang dihargai oleh konsumen. Maka, keakuratan prediksi tidak hanya berbicara tentang metrik teknis, tetapi juga tentang kepekaan terhadap harapan dan persepsi pengguna.

Selain precision, recall, dan *F1-score*, akurasi juga tetap digunakan sebagai referensi, meskipun keterbatasannya pada data tidak seimbang harus diperhatikan. Dalam beberapa kasus, model dengan akurasi tinggi justru memiliki performa buruk pada kelas minoritas. Oleh karena itu, evaluasi tidak boleh dilakukan secara tunggal. Penggunaan metrik ganda memungkinkan interpretasi yang lebih utuh, serta mendukung pengambilan keputusan strategis yang lebih presisi.

Di era transformasi digital yang menuntut kecepatan dan ketepatan layanan, kemampuan sebuah sistem untuk membaca sentimen pengguna secara akurat menjadi keunggulan kompetitif. Evaluasi yang tepat, menyeluruh, dan berkelanjutan menjamin bahwa model yang digunakan tidak hanya bekerja secara matematis, tetapi juga relevan dalam memenuhi kebutuhan nyata di lapangan. Oleh karena itu, proses ini bukanlah tahap akhir, melainkan bagian dari siklus pengembangan yang terus disempurnakan.

Dalam penerapannya pada skala industri, hasil evaluasi digunakan untuk menetapkan standar kinerja,

membandingkan model alternatif, dan menentukan apakah sistem layak untuk diintegrasikan dalam proses operasional. Model dengan performa unggul di tahap evaluasi biasanya akan diuji kembali dengan data baru untuk mengukur kestabilan dan generalisasi. Langkah ini penting guna menghindari overfitting, yakni kondisi saat model hanya bekerja baik pada data pelatihan namun gagal saat dihadapkan pada data baru.

Evaluasi juga membuka ruang bagi kolaborasi antardivisi, karena hasilnya bisa menjadi dasar untuk tim produk, pemasaran, dan layanan pelanggan dalam menyusun rencana taktis. Oleh sebab itu, dokumentasi yang baik dari hasil evaluasi, termasuk grafik performa, matriks klasifikasi, dan ringkasan metrik, menjadi alat komunikasi yang membantu menjembatani aspek teknis dengan kebutuhan operasional.

n.

Precision, Recall, dan F1-Score

Evaluasi kinerja model dalam klasifikasi sering kali mengandalkan tiga metrik utama: precision, recall, dan F1-score. Metrik-metrik ini saling berkaitan dan memberikan gambaran yang lebih komprehensif mengenai kinerja model dalam mengklasifikasikan data. Dalam konteks analisis sentimen, precision, recall, dan F1-score digunakan

untuk menilai seberapa baik model dapat mengklasifikasikan sentimen positif, negatif, atau netral dari ulasan produk.

1. **Precision** adalah metrik yang mengukur seberapa banyak prediksi positif yang benar-benar positif. Precision dihitung sebagai rasio antara jumlah true positive (TP) dan jumlah seluruh prediksi yang positif (TP + FP), dengan rumus:

$$\text{Precision} = \frac{TP}{TP + FP}$$

Precision sangat penting ketika kesalahan dalam memprediksi sentimen positif dapat menyebabkan interpretasi yang keliru mengenai kualitas produk, misalnya, menyatakan bahwa produk berkualitas padahal sebenarnya tidak. Agarwal et al. (2020) mengungkapkan bahwa precision adalah metrik yang sangat krusial dalam aplikasi-aplikasi sensitif, seperti diagnosis medis, di mana kesalahan dalam mengklasifikasikan positif dapat menimbulkan dampak yang signifikan, seperti pengobatan yang tidak perlu.

2. **Recall**, di sisi lain, mengukur kemampuan model untuk mendeteksi seluruh instansi positif yang ada

dalam dataset. Metrik ini sangat penting dalam konteks ketidakseimbangan kelas, di mana kelas minoritas (misalnya, sentimen negatif) bisa saja terabaikan jika hanya mengandalkan akurasi atau precision saja. Recall dihitung dengan rumus:

$$\text{Recall} = \frac{TP}{TP + FN}$$

Dengan recall yang lebih tinggi, model menunjukkan bahwa ia mampu menangkap lebih banyak sentimen yang benar-benar positif (atau negatif), meskipun beberapa prediksi positif tersebut mungkin salah. Fontes et al. (2022) menekankan bahwa recall sangat berguna ketika tujuannya adalah untuk menangkap sebanyak mungkin instansi yang relevan, bahkan jika itu berarti menghasilkan lebih banyak false positives.

3. **F1-Score** merupakan rata-rata harmonis antara precision dan recall, yang memberikan nilai yang lebih seimbang dalam menilai kinerja model. F1-score dihitung dengan rumus:

$$\text{F1-score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

F1-score penting dalam konteks di mana terdapat trade-off antara precision dan recall. Peningkatan satu metrik mungkin menyebabkan penurunan metrik lainnya. Oleh karena itu, F1-score memberikan gambaran yang lebih adil tentang kinerja model, terutama dalam dataset yang tidak seimbang. Gøttcke & Zimek (2021) menyatakan bahwa F1-score sangat berguna untuk menilai model di mana tidak ada metrik yang dapat diandalkan secara tunggal untuk menggambarkan kinerja keseluruhan, terutama pada kasus di mana jumlah data untuk setiap kelas sangat berbeda.

Macro Average vs. Weighted Average

Dalam evaluasi model multi-kelas, seperti dalam analisis sentimen yang melibatkan lebih dari dua kelas (positif, negatif, dan netral), kita sering kali menggunakan dua pendekatan untuk menghitung rata-rata metrik evaluasi: macro average dan weighted average. Kedua pendekatan ini memberikan pandangan yang berbeda tentang bagaimana kinerja model pada berbagai kelas, yang sering kali memiliki jumlah sampel yang sangat bervariasi.

1. **Macro Average** menghitung metrik evaluasi (precision, recall, atau F1-score) untuk setiap kelas secara terpisah dan kemudian menghitung rata-rata

dari nilai-nilai tersebut. Setiap kelas diperlakukan secara setara, tanpa mempertimbangkan jumlah sampel dalam kelas tersebut. Dengan kata lain, macro average memberi bobot yang sama pada setiap kelas. Formula untuk macro average adalah:

$$\text{Macro Average} = \frac{1}{N} \sum_{i=1}^N \text{Metrik Kelas}_i$$

Ozturk et al. (2024) menjelaskan bahwa macro average memberikan gambaran yang lebih adil tentang kinerja model pada setiap kelas, khususnya ketika kita ingin memastikan bahwa model tidak hanya berfokus pada kelas mayoritas. Namun, macro average bisa menjadi tidak ideal dalam dataset yang tidak seimbang, karena dapat menyembunyikan kinerja buruk pada kelas minoritas.

2. **Weighted Average**, di sisi lain, menghitung rata-rata metrik dengan memperhatikan jumlah sampel dalam setiap kelas. Setiap kelas diberi bobot berdasarkan jumlah data yang ada dalam kelas tersebut, sehingga kelas dengan lebih banyak sampel akan mempengaruhi hasil rata-rata lebih besar. Formula untuk weighted average adalah:

$$\text{Weighted Average} = \sum_{i=1}^N \frac{\text{Jumlah Sampel Kelas}_i}{\text{Jumlah Sampel Total}} \times \text{Metrik Kelas}_i$$

Weighted average sangat berguna dalam situasi di mana dataset memiliki distribusi kelas yang tidak seimbang, karena memberikan gambaran yang lebih realistis mengenai kinerja model, terutama untuk kelas mayoritas yang lebih besar. Fontes et al. (2022) menjelaskan bahwa weighted average lebih tepat digunakan dalam dataset yang tidak seimbang karena ia memperhitungkan distribusi kelas dalam evaluasi keseluruhan.

Penerapan dalam Evaluasi Model Sentimen

Dalam penelitian ini, digunakan tiga model klasifikasi—Naive Bayes, SVM, dan Decision Tree—yang dievaluasi menggunakan metrik precision, recall, dan F1-score untuk masing-masing kelas sentimen: positif, negatif, dan netral. Evaluasi dilakukan dengan mengacu pada nilai macro average dan weighted average, untuk memahami kinerja model terhadap distribusi kelas yang tidak seimbang.

- a. Model SVM menunjukkan kinerja unggul dalam mendeteksi sentimen negatif, dengan F1-score yang tinggi meskipun jumlah data negatif lebih

sedikit. Ini menunjukkan kemampuan SVM dalam menangkap informasi penting dari ulasan negatif, yang sering kali krusial dalam evaluasi produk.

- b. Naive Bayes bekerja baik pada kelas mayoritas, namun memiliki precision rendah pada kelas negatif. Ini menandakan kelemahannya dalam menangani kelas minoritas, yang perlu diatasi melalui pendekatan resampling atau tuning model.
- c. Decision Tree unggul dari segi interpretasi, tetapi performa dalam mengklasifikasikan sentimen negatif masih lemah. Model ini cocok untuk pemodelan awal, namun butuh pengoptimalan lebih lanjut.

Kombinasi macro dan weighted average membantu memberikan gambaran menyeluruh: macro average menilai performa antar kelas secara seimbang, sedangkan weighted average memperhitungkan distribusi aktual kelas dalam dataset.

2. Aplikasi

Kode Python

```

1 # Import pustaka yang diperlukan
2 import pandas as pd
3 from sklearn.model_selection import train_test_split
4 from sklearn.feature_extraction.text import TfidfVectorizer
5 from sklearn.svm import SVC
6 from sklearn.naive_bayes import MultinomialNB
7 from sklearn.metrics import classification_report
8 # Contoh dataset sentimen tiga kelas: Positive, Negative, Neutral
9 data = {
10     'text': [
11         'Produk ini sangat bagus dan berkualitas',      # Positive
12         'Saya sangat kecewa dengan layanan ini',        # Negative
13         'Pengiriman cepat dan produk sesuai deskripsi', # Positive
14         'Barang rusak saat diterima, sangat mengecewakan', # Negative
15         'Luar biasa, saya akan beli lagi!',             # Positive
16         'Tidak sesuai ekspektasi, kualitas buruk',      # Negative
17         'Barang datang tepat waktu, oke saja',          # Neutral
18         'Pelayanan cukup memuaskan, tapi biasa saja',  # Neutral
19         'Tidak buruk, tapi juga tidak luar biasa',      # Neutral
20     ],
21     'sentiment': [
22         'Positive', 'Negative', 'Positive', 'Negative', 'Positive',
23         'Negative', 'Neutral', 'Neutral', 'Neutral'
24     ]
25 }
26 # Membuat DataFrame
27 df = pd.DataFrame(data)
28 # Memisahkan fitur dan label
29 X = df['text']
30 y = df['sentiment']
31 # Membagi data ke dalam data latih dan uji
32 X_train, X_test, y_train, y_test = train_test_split(
33     X, y, test_size=0.33, random_state=42, stratify=y
34 )

```

```

35 # TF-IDF Vectorization
36 vectorizer = TfidfVectorizer(stop_words='english', max_features=5000)
37 X_train_tfidf = vectorizer.fit_transform(X_train)
38 X_test_tfidf = vectorizer.transform(X_test)
39 # Model SVM
40 svm_model = SVC(kernel='linear')
41 svm_model.fit(X_train_tfidf, y_train)
42 y_pred_svm = svm_model.predict(X_test_tfidf)
43 print("SVM Classification Report:")
44 print(classification_report(y_test, y_pred_svm, zero_division=0))
45 # Model Naive Bayes
46 nb_model = MultinomialNB()
47 nb_model.fit(X_train_tfidf, y_train)
48 y_pred_nb = nb_model.predict(X_test_tfidf)
49 print("Naive Bayes Classification Report:")
50 print(classification_report(y_test, y_pred_nb, zero_division=0))

```

Output Program

SVM Classification Report:

	precision	recall	f1-score	support
Negative	0.00	0.00	0.00	1.0
Neutral	0.00	0.00	0.00	1.0
Positive	0.00	0.00	0.00	1.0
accuracy			0.00	3.0
macro avg	0.00	0.00	0.00	3.0
weighted avg	0.00	0.00	0.00	3.0

Naive Bayes Classification Report:

	precision	recall	f1-score	support
Negative	0.00	0.00	0.00	1
Neutral	0.33	1.00	0.50	1
Positive	0.00	0.00	0.00	1
accuracy			0.33	3
macro avg	0.11	0.33	0.17	3
weighted avg	0.11	0.33	0.17	3

Tampilan di atas menunjukkan hasil evaluasi model SVM dan Naive Bayes pada klasifikasi sentimen tiga kelas:

negatif, netral, dan positif. Model SVM gagal total dalam memprediksi semua kelas, dengan precision, recall, dan f1-score bernilai nol. Ini menunjukkan bahwa SVM tidak mampu mengenali satu pun kelas dengan benar, kemungkinan karena jumlah data uji yang sangat kecil (1 sampel per kelas). Naive Bayes sedikit lebih baik, berhasil mengenali satu kelas (netral) dengan recall 1.00 dan f1-score 0.50, namun tetap gagal pada kelas negatif dan positif. Hasil ini mencerminkan kurangnya generalisasi model akibat data yang terlalu sedikit atau distribusi kelas yang tidak seimbang.

3. Studi Kasus

Tabel 2. Perbandingan Kinerja Model

Model	Cross-Val F1 ($\mu \pm \sigma$)	Test Accuracy	Test F1-Score
SVM	0.9832 $\pm$ 0.0035	94.61%	94.79%
Decision Tree	0.9554 $\pm$ 0.0097	85.93%	87.82%
Naive Bayes	0.9326 $\pm$ 0.0080	82.04%	84.90%

Tabel di atas menunjukkan perbandingan kinerja tiga model klasifikasi (SVM, Decision Tree, dan Naive Bayes) yang digunakan dalam analisis sentimen pada dataset ulasan produk e-commerce. Evaluasi dilakukan berdasarkan tiga metrik utama:

1. Cross-Val F1 ($\mu \pm \sigma$)

Metrik ini mengukur performa model melalui evaluasi silang (cross-validation) dan menunjukkan rata-rata nilai F1-score beserta deviasi standar. SVM menunjukkan nilai F1 yang sangat tinggi dan stabil (0.9832 ± 0.0035), yang menunjukkan konsistensi dan efektivitas model dalam berbagai subset data.

2. Test Accuracy

Metrik ini mengukur akurasi model dalam mengklasifikasikan data uji. SVM memiliki akurasi tertinggi (94.61%), diikuti oleh Decision Tree (85.93%), dan Naive Bayes (82.04%). Ini menunjukkan bahwa SVM lebih efektif dalam memprediksi data uji dengan akurasi yang lebih tinggi.

3. Test F1-Score

Metrik ini memberikan gambaran tentang keseimbangan antara precision dan recall pada data uji. SVM memiliki nilai F1-Score tertinggi (94.79%), menunjukkan bahwa model ini tidak hanya memiliki akurasi tinggi tetapi juga keseimbangan yang baik dalam mendeteksi berbagai sentimen (positif, negatif, netral).

4. Soal Latihan

- 1) Jelaskan apa yang dimaksud dengan precision dalam konteks model klasifikasi dan bagaimana precision dihitung. Berikan contoh bagaimana precision dapat mempengaruhi hasil evaluasi dalam analisis sentimen.
- 2) Apa perbedaan antara precision dan recall? Jelaskan mengapa recall menjadi sangat penting dalam model yang digunakan untuk menganalisis data yang tidak seimbang, seperti dalam analisis sentimen ulasan produk.
- 3) Definisikan F1-score dan jelaskan mengapa F1-score sering digunakan dalam evaluasi model pada dataset yang tidak seimbang. Bagaimana F1-score menggabungkan precision dan recall untuk memberikan gambaran kinerja model yang lebih seimbang?
- 4) Berikan penjelasan tentang perbedaan antara macro average dan weighted average dalam evaluasi model multi-kelas. Kapan masing-masing pendekatan lebih disarankan untuk digunakan?
- 5) Dari hasil perbandingan kinerja model pada Tabel 2, mana yang menunjukkan kinerja terbaik dalam analisis sentimen? Berdasarkan nilai Cross-Val F1, Test Accuracy, dan Test F1-Score, apa alasan utama

di balik pemilihan model tersebut sebagai yang paling efektif?

Daftar Pustaka

- Agarwal, A., Chivukula, A., Bhuyan, M., Jan, T., Narayan, B., & Prasad, M. (2020). Identification and classification of cyberbullying posts: a recurrent neural network approach using under-sampling and class weighting. *Proceedings of the International Conference on Data Science and Machine Learning*, 113-120. https://doi.org/10.1007/978-3-030-63823-8_14
- Araújo, M., Dommelen, P., Koledova, E., & Srivastava, J. (2021). Using deep learning for individual-level predictions of adherence with growth hormone therapy. *Journal of Medical Informatics*, 52(3), 402-410. <https://doi.org/10.3233/shti210135>
- Biloborodova, T., Skarga-Bandurova, I., Koverha, M., Skarha-Bandurov, I., & Yevsieieva, Y. (2021). A learning framework for medical image-based intelligent diagnosis from imbalanced datasets. *Proceedings of the International Conference on Machine Learning*, 47-56. <https://doi.org/10.3233/shti210801>
- Fontes, G., Matos, L., Matta, A., Pilastri, A., & Cortez, P. (2022). An empirical study on anomaly detection algorithms for extremely imbalanced datasets. *Proceedings of the International Conference on Data Science*, 85-95. https://doi.org/10.1007/978-3-031-08333-4_7
- Gøttcke, J. and Zimek, A. (2021). Handling class imbalance in k-nearest neighbor classification by balancing prior probabilities. *Proceedings of the International Conference on Machine Learning*, 247-261. https://doi.org/10.1007/978-3-030-89657-7_19

Analisis Platform

1. Konsep Dasar

Pemahaman awal mengenai pemetaan persepsi pengguna di berbagai platform e-commerce menyoroti pentingnya interaksi digital dan bagaimana pengalaman bertransaksi membentuk citra suatu layanan daring. Pengamatan tidak hanya tertuju pada struktur aplikasi atau fitur-fitur pendukung, melainkan lebih dalam mencermati pola kebiasaan pengguna, preferensi belanja, serta respons emosional yang muncul dan terekam dalam bentuk ulasan yang mereka bagikan. Di tengah ekosistem digital Indonesia, Shopee dan Tokopedia menjadi dua entitas dominan yang menunjukkan perbedaan mencolok dalam ekspresi pengguna, tergambar dari distribusi sentimen yang beragam. Fenomena ini mengindikasikan bahwa rancangan operasional dan pendekatan layanan memiliki peran besar dalam membentuk persepsi dan kepuasan yang pada akhirnya memengaruhi narasi yang berkembang di kalangan pengguna.. Pendekatan ini tidak hanya melihat elemen struktural dari aplikasi atau fitur teknis semata, melainkan menelusuri bagaimana pola perilaku, preferensi konsumen, dan respons emosional terhadap layanan dan produk tercermin melalui ulasan yang ditinggalkan. Di

Indonesia, Shopee dan Tokopedia mewakili dua platform dominan yang menunjukkan perbedaan signifikan dalam lanskap persepsi pengguna, yang terpotret melalui komposisi sentimen yang mereka hasilkan. Hal ini memberikan cerminan bahwa karakteristik operasional dan strategi layanan sangat berpengaruh terhadap bagaimana konsumen mengungkapkan pengalaman mereka.

Shopee memperlihatkan dominasi sentimen positif yang mengarah pada keberhasilan penerapan strategi diskon, promosi berbasis waktu, dan integrasi fitur sosial seperti rating visual dan ulasan berbasis media. Keleluasaan sistem pembayaran, efisiensi pengiriman, serta akses pada program loyalitas menciptakan pengalaman yang dirasakan sebagai efisien dan menyenangkan, sehingga sebagian besar konsumen terdorong untuk memberikan respons positif. Walaupun begitu, sentimen negatif tetap hadir dalam jumlah terbatas, umumnya berkaitan dengan inkonsistensi kualitas produk, keterlambatan logistik, atau perbedaan antara ekspektasi dan kenyataan dari sisi barang yang diterima.

Tokopedia, di sisi lain, mencerminkan lanskap evaluasi yang lebih seimbang, mencakup proporsi sentimen positif, netral, dan negatif yang hampir setara. Keragaman kategori produk dan kebebasan dalam memilih penjual berkontribusi pada kompleksitas pengalaman yang dialami pengguna.

Hal ini tercermin dalam variasi ulasan yang lebih detail, mencakup apresiasi terhadap harga dan ketersediaan, namun juga menyampaikan kekecewaan terkait keakuratan deskripsi, waktu pengiriman, dan respons layanan. Perbedaan ini menunjukkan bahwa pengguna Tokopedia cenderung mengungkapkan pengalaman mereka secara reflektif, tidak hanya pada momen kepuasan tetapi juga pada ketidakpuasan, dengan gaya naratif yang lebih deskriptif dan argumentatif.

Strategi komunikasi merek yang efektif sangat dipengaruhi oleh karakteristik ini. Di Shopee, pendekatan visual dan promosi instan lebih sesuai untuk memperkuat citra sebagai platform cepat, terjangkau, dan menyenangkan. Tokopedia menuntut pendekatan yang menekankan nilai informasi dan pengalaman yang cermat, di mana transparansi produk, konsistensi pelayanan, dan akurasi deskripsi menjadi daya tarik utama. Narasi yang dibentuk pun harus mencerminkan suara konsumen masing-masing platform, baik yang bersifat antusiasme spontan maupun evaluasi mendalam. Komunikasi berbasis pengalaman nyata yang dikemas dalam bentuk yang relevan dengan gaya pengguna akan memperkuat keterikatan dan kepercayaan.

Penerapan strategi personalisasi turut menjadi bagian integral dari pendekatan platform-spesifik. Shopee

memanfaatkan rekam jejak interaksi pengguna untuk menyajikan rekomendasi dinamis yang mengedepankan promo, sementara Tokopedia cenderung mendorong eksplorasi produk dan interaksi komunitas melalui fitur ulasan panjang dan diskusi. Pendekatan ini mencerminkan pengakuan terhadap preferensi dan pola konsumsi yang berbeda pada tiap basis pengguna.

Dalam pengambilan keputusan yang berbasis pada data sentimen, evaluasi distribusi ulasan dapat dijadikan acuan untuk menyesuaikan strategi penjualan, kualitas produk, dan layanan pendukung secara lebih terarah. Identifikasi dominasi atau kekurangan sentimen tertentu membuka peluang untuk perbaikan, sekaligus memberikan dasar kuat dalam membangun reputasi digital. Ketika pelaku usaha merespons dinamika sentimen secara aktif dan adaptif, maka loyalitas konsumen dapat terjaga bahkan dalam kondisi kompetitif yang tinggi.

Dinamika Pengaruh Ulasan Positif dan Negatif pada Platform E-Commerce

Perbedaan distribusi sentimen ini menyoroti pentingnya analisis ulasan produk secara spesifik berdasarkan karakteristik platform. Di platform seperti Shopee, yang didominasi oleh ulasan positif, analisis sentimen lebih berfokus pada elemen-elemen yang

mengindikasikan kepuasan dan pengalaman positif pengguna. Namun, analisis sentimen di platform seperti Tokopedia yang memiliki distribusi sentimen lebih seimbang harus lebih komprehensif, melibatkan analisis sentimen positif dan negatif untuk memastikan pemahaman yang lebih baik mengenai pengalaman pengguna dan untuk menjaga keseimbangan yang sesuai dengan kebutuhan konsumen.

Penelitian menunjukkan bahwa sentimen positif dapat memengaruhi perilaku konsumen dan keputusan pembelian dengan meningkatkan niat beli dan frekuensi pembelian kembali. Konsumen lebih cenderung melakukan pembelian impulsif ketika mereka merasa positif terhadap platform, yang dipicu oleh pengalaman berbelanja yang menyenangkan dan interaksi dalam ruang sosial promosi (Anwar & Padmantyo, 2023). Selain itu, sentimen positif juga dapat merangsang electronic word-of-mouth (eWOM), yang mendorong pengguna baru untuk bergabung dengan platform, sehingga dapat meningkatkan tingkat akuisisi dan retensi pengguna (Santy et al., 2024; Kugblenu et al., 2022).


Implikasi Praktis untuk Perusahaan E-Commerce

Bagi perusahaan e-commerce, memahami karakteristik platform tempat mereka beroperasi sangat

penting untuk merancang strategi pemasaran dan pelayanan yang lebih efektif. Untuk platform seperti Shopee yang memiliki dominasi sentimen positif, perusahaan perlu fokus pada penguatan elemen-elemen yang mendorong kepuasan pengguna, seperti kecepatan pengiriman dan pelayanan pelanggan yang responsif. Selain itu, pemantauan terhadap ulasan negatif, meskipun lebih sedikit, tetap diperlukan untuk memastikan bahwa masalah yang diungkapkan konsumen dapat segera ditangani dengan baik (Lestari et al., 2023).

Di sisi lain, pada platform seperti Tokopedia yang memiliki distribusi sentimen yang lebih seimbang, perusahaan perlu menangani berbagai jenis sentimen yang ada dengan bijaksana. Selain berfokus pada kepuasan pengguna, perusahaan harus memperhatikan keluhan yang lebih bervariasi dan mengidentifikasi masalah yang mungkin muncul pada kategori produk tertentu. Pemahaman yang lebih dalam tentang dinamika ulasan di setiap platform memungkinkan perusahaan untuk merancang strategi yang lebih sesuai dengan ekspektasi dan kebutuhan pelanggan (Ding, 2023; Ramelan et al., 2023).

2. Aplikasi



Gambar 3. Distribusi Jumlah Ulasan Per Platform E-Commerce

Dalam analisis sentimen pada platform e-commerce, visualisasi distribusi sentimen yang muncul dari ulasan produk menjadi langkah yang sangat penting. Gambar yang dihasilkan menunjukkan perbedaan jumlah ulasan yang diberikan oleh konsumen pada berbagai platform e-commerce di Indonesia, yaitu Shopee, Lazada, Tokopedia, Bilibli, dan Bukalapak. Dengan memvisualisasikan jumlah ulasan berdasarkan platform ini, kita bisa melihat seberapa aktif konsumen memberikan umpan balik terhadap produk dan layanan yang ditawarkan pada masing-masing platform.

Gambar 3, yang menunjukkan jumlah ulasan per platform, memperlihatkan Shopee dengan jumlah ulasan

terbanyak yaitu 589 ulasan, yang menandakan tingginya keterlibatan pengguna dalam platform ini. Hal ini sangat sejalan dengan dominasi sentimen positif yang ditemukan di Shopee, di mana banyak konsumen yang merasa puas dengan kualitas produk, pengiriman cepat, dan layanan pelanggan yang responsif (Ranti et al., 2023). Angka ini juga mencerminkan strategi pemasaran yang berhasil, seperti diskon dan promosi besar, yang memicu interaksi positif dari pengguna.

Di sisi lain, Lazada dengan 265 ulasan, Tokopedia dengan 264 ulasan, dan Blibli dengan 214 ulasan, menunjukkan tingkat keterlibatan yang signifikan meskipun jumlahnya lebih rendah dibandingkan Shopee. Meskipun sentimen positif tetap dominan pada ketiga platform ini, distribusi sentimen yang lebih beragam terlihat, dengan sentimen negatif dan netral yang lebih banyak dibandingkan Shopee, menunjukkan pengalaman yang lebih beragam dari konsumen (Prabowo et al., 2023).

Sedangkan Bukalapak, yang hanya memiliki 3 ulasan, menunjukkan tingkat keterlibatan yang sangat rendah, yang dapat mengindikasikan kurangnya minat atau aktivitas pengguna pada platform tersebut. Hal ini mungkin mengindikasikan tantangan yang dihadapi Bukalapak dalam menarik konsumen dibandingkan dengan platform-platform besar lainnya seperti Shopee dan Tokopedia.

Dengan visualisasi ini, perusahaan e-commerce dapat lebih mudah memahami dinamika sentimen dan tingkat keterlibatan pengguna di berbagai platform. Strategi yang lebih disesuaikan dapat dikembangkan untuk meningkatkan kepuasan pelanggan dan memaksimalkan potensi penjualan di setiap platform.

3. Studi Kasus

Dalam analisis sentimen pada platform e-commerce, salah satu tantangan utama adalah bias model yang dapat muncul akibat perbedaan distribusi sentimen antar platform. Setiap platform e-commerce memiliki karakteristik dan dinamika pengguna yang unik, yang dapat memengaruhi hasil analisis sentimen. Sebagai contoh, Shopee dengan dominasi sentimen positif memiliki kecenderungan menghasilkan model yang bias terhadap sentimen positif. Sebaliknya, platform dengan distribusi sentimen yang lebih seimbang seperti Tokopedia dapat menyebabkan model kesulitan dalam menanggapi sentimen negatif atau netral dengan seimbang.

Untuk menangani masalah ini, strategi yang tepat diperlukan dalam penyesuaian model dan pengolahan data. Salah satu pendekatan yang umum digunakan adalah penyesuaian bobot kelas (class weighting). Metode ini

memberikan bobot yang lebih tinggi pada sentimen yang kurang terwakili, seperti sentimen negatif, untuk memastikan model dapat mengenali dan memprosesnya secara tepat (Gøttcke & Zimek, 2021). Dalam kasus platform seperti Shopee, di mana sentimen positif lebih mendominasi, pemberian bobot yang lebih tinggi pada sentimen negatif atau netral dapat membantu model menghindari bias terhadap kategori yang lebih sering muncul.

Strategi lainnya adalah dengan menggunakan teknik resampling seperti SMOTE (Synthetic Minority Over-sampling Technique) dan SMOTEENN (SMOTE and Edited Nearest Neighbors). Teknik ini bertujuan untuk menambah jumlah data dari kelas minoritas, sehingga model dapat belajar dengan lebih baik untuk mengenali pola sentimen yang tidak terlalu sering muncul (He & Yu, 2022). Melalui teknik-teknik ini, model dapat ditingkatkan untuk lebih adaptif terhadap distribusi sentimen yang beragam, yang membantu dalam menghasilkan prediksi yang lebih akurat dan mengurangi bias.

Dalam praktiknya, penting untuk menyesuaikan pendekatan ini sesuai dengan karakteristik masing-masing platform, memastikan analisis sentimen yang lebih adil dan representatif bagi seluruh tipe pengguna.

3. Soal Latihan

- 1) Jelaskan faktor-faktor yang menyebabkan dominasi sentimen positif pada platform e-commerce seperti Shopee. Bagaimana faktor-faktor tersebut mempengaruhi pengalaman pengguna dan keputusan pembelian konsumen?
- 2) Analisis perbedaan distribusi sentimen antara platform Shopee dan Tokopedia. Apa yang membedakan keduanya, dan bagaimana hal ini mempengaruhi cara analisis sentimen dilakukan pada masing-masing platform?
- 3) Apa yang dimaksud dengan bias model dalam analisis sentimen e-commerce, dan bagaimana perbedaan distribusi sentimen di Shopee dan Tokopedia dapat menyebabkan bias tersebut? Jelaskan strategi yang dapat digunakan untuk menangani bias model akibat perbedaan distribusi ini.
- 4) Diskusikan bagaimana teknik resampling seperti SMOTE dan SMOTEENN dapat digunakan untuk mengatasi masalah ketidakseimbangan kelas dalam analisis sentimen pada platform dengan distribusi sentimen yang tidak merata. Berikan contoh penerapannya pada Shopee dan Tokopedia.
- 5) Bagaimana visualisasi distribusi sentimen per platform dapat membantu perusahaan e-commerce dalam

merancang strategi pemasaran? Diskusikan peran penting visualisasi ini dalam mengidentifikasi kekuatan dan kelemahan masing-masing platform.

DAFTAR PUSTAKA

- Anwar, L. and Padmantyo, S. (2023). The effect of brand awareness and e-wom on purchase intention: evidence from Indonesia's online food delivery. 751-765. https://doi.org/10.2991/978-94-6463-204-0_62
- Oetarjo, M., Rohim, D., Firdaus, V., & Togayev, S. (2023). Online reviews and ratings shape purchasing decisions in Indonesian e-commerce. 557-566. https://doi.org/10.2991/978-2-38476-052-7_61
- Prabowo, S., Parahiyanti, C., Dewi, Y., Aulisaina, F., & Aziz, N. (2023). The fierce competition of Shopee battlefield among generation Z consumers. 39-47. https://doi.org/10.2991/978-94-6463-302-3_6
- Ranti, N., Agung, D., & Ellitan, L. (2023). The impact of security and e-wom on purchase decisions with trust as mediator in online shopping through the Shopee application. 346-359. https://doi.org/10.2991/978-94-6463-076-3_26
- Santy, R., Hamdani, M., & Rahma, S. (2024). Enhancing online purchase intention through artificial intelligence: transformation to digital customer experience. 120-135. https://doi.org/10.2991/978-94-6463-465-5_11

Ujian Akhir Semester

Ujian Akhir Semester (UAS)

Cakupan: Pertemuan 9–15

Format Ujian:

1. **Praktikum**
2. **Essai**
3. **Studi Kasus**

1. Praktikum (30%)

Tugas 1: Preprocessing Teks Ulasan Produk

Deskripsi Tugas:

Lakukan preprocessing pada teks ulasan produk. Ikuti langkah-langkah berikut:

Normalisasi Slang

Ubah slang menjadi bentuk baku. Contoh: 'bgt' → 'banget', 'tp' → 'tapi'.

Tokenisasi Teks

Pisahkan teks menjadi unit terkecil (kata atau frasa).

Penghapusan Stopword

Gunakan daftar stopwords berikut: ["yang", "di", "yg", "dg", "tp"].

Stemming

Gunakan pustaka **Sastrawi** untuk stemming kata-kata.

Output:

Daftar token yang telah diproses.

Tugas 2: Ekstraksi Fitur TF-IDF

Deskripsi Tugas:

Hitung vektor **TF-IDF** untuk dua dokumen ulasan produk:

1. "Pengiriman cepat, produk sesuai gambar"
2. "Pengiriman lambat, produk tidak sesuai"

Gunakan parameter berikut:

`ngram_range = (1, 2)`

`max_features = 5`

Output:

Matriks TF-IDF

Daftar fitur terpilih

Tugas 3: Pelatihan Model Word2Vec

Deskripsi Tugas:

Latih model **Word2Vec** dengan data berikut:

`[["saya", "puas", "produk", "ini"], ["saya", "kecewa", "beli", "produk", "itu"]]`

Gunakan parameter:

`vector_size = 5`

window = 2

min_count = 1

Output:

Vektor untuk kata "**puas**" dan "**kecewa**".

Tugas 4: Penerapan SMOTE untuk Ketidakseimbangan Kelas

Deskripsi Tugas:

Dataset:

Fitur: $X = [[0.1], [0.2], [0.3], [0.4], [0.5]]$

Label: $y = [0, 0, 0, 0, 1]$ (Kelas minoritas = 1)

Terapkan **SMOTE** (Synthetic Minority Over-sampling Technique) untuk menambah sampel kelas minoritas dengan **rasio = 0.5**.

Output:

Jumlah sampel sebelum dan sesudah SMOTE

Tugas 5: Integrasi Fitur Multimodal

Deskripsi Tugas:

Gabungkan matriks fitur berikut:

TF-IDF (sparse): $[[0.8, 0.2], [0.4, 0.6]]$

Word2Vec (dense): $[[0.1, 0.3], [0.2, 0.4]]$

Gunakan **scipy.sparse.hstack** untuk menggabungkan fitur dan konversikan fitur Word2Vec ke sparse.

Output:

Matriks fitur gabungan dalam bentuk array

2. Essai (40%)

Pilih 3 dari pertanyaan berikut untuk dijawab.

Jawaban harus mencakup analisis mendalam dan contoh-contoh aplikatif.

- 1) Jelaskan mengapa ulasan negatif seringkali lebih bernilai bisnis daripada ulasan positif dalam konteks e-commerce. Berikan contoh strategi respons berbasis analisis sentimen yang dapat digunakan oleh perusahaan untuk meningkatkan reputasi dan kepuasan pelanggan.
- 2) Mengapa normalisasi slang (misalnya, 'bgt' → 'banget') dan stemming menggunakan pustaka Sastrawi penting dalam pemrosesan bahasa alami (NLP) untuk bahasa Indonesia? Bandingkan tantangan ini dengan preprocessing untuk bahasa Inggris dan jelaskan perbedaan mendasar yang perlu diperhatikan.
- 3) Analisis mengapa penggunaan bigram seperti "tidak puas" lebih informatif dalam analisis sentimen dibandingkan unigram "puas" dalam **TF-IDF**. Berikan

contoh perhitungan bobot TF-IDF untuk kedua kasus ini dan diskusikan dampaknya terhadap hasil analisis sentimen.

- 4) Jelaskan bagaimana **Word2Vec** menangkap relasi semantis antara kata "**puas**" (satisfied) dan "**kecewa**" (disappointed). Mengapa operasi vektor seperti 'puas' - 'senang' + 'marah' tidak valid dalam konteks analisis sentimen?
- 5) Mengapa akurasi 85% pada dataset yang tidak seimbang (80% ulasan positif, 20% ulasan negatif) bisa menyesatkan? Hitung **recall** untuk kelas minoritas (negatif) jika model hanya memprediksi 1 ulasan negatif dengan benar dari total 5 ulasan negatif.
- 6) Jelaskan prinsip dasar **SMOTE** dan **SMOTEENN** serta mengapa teknik SMOTEENN lebih efektif dalam mengatasi sampel ambigu daripada SMOTE standalone. Berikan contoh bagaimana teknik ini dapat meningkatkan kualitas model dalam analisis sentimen untuk dataset yang sangat tidak seimbang.

3. Studi Kasus (30%)

3.1 Studi Kasus: Penerapan Teknik Resampling pada Ulasan Produk E-Commerce

Diberikan dataset ulasan produk yang tidak seimbang, dengan distribusi kelas sebagai berikut:

80% ulasan positif

15% ulasan netral

5% ulasan negatif

Tugas:

Terapkan **SMOTE** dan **SMOTEENN** untuk menyeimbangkan dataset.

Evaluasi hasil resampling dengan menggunakan metrik **precision**, **recall**, dan **F1-score** untuk masing-masing kelas (positif, netral, negatif).

Diskusikan tantangan yang mungkin muncul selama proses ini, termasuk kemungkinan **overfitting** dan **noise** dalam data.

Berikan rekomendasi untuk meningkatkan performa model setelah resampling, baik dari sisi teknik resampling ataupun penggunaan model lain yang lebih efektif dalam mengatasi ketidakseimbangan kelas.

Output:

Langkah-langkah penerapan SMOTE dan SMOTEENN dengan Python.

Evaluasi hasil resampling menggunakan metrik evaluasi model.

Rekomendasi langkah-langkah pengembangan model yang lebih baik.

Kriteria Penilaian:

Praktikum:

Ketepatan sintaksis (50%)

Ketepatan output (50%)

Essai:

Kedalaman analisis dan pemahaman (40%)

Relevansi solusi yang diberikan (30%)

Contoh konkret dan aplikatif (30%)

Studi Kasus:

Penggunaan teknik resampling yang tepat
(30%)

Kemampuan untuk menganalisis dan
mengevaluasi hasil resampling (30%)

Rekomendasi untuk pengembangan model
yang efektif (40%)

Biodata Penulis



Shabrina Rasyid Munthe, S.Pd.I., M.S., seorang akademisi berdedikasi yang lahir di Rantauprapat pada 20 Februari 1992. Beliau menyelesaikan studi S1 di bidang Tarbiyah di IAIN Padangsidimpuan dan meraih gelar Magister Sastra dari Universitas Islam Sumatera Utara (UISU). Sejak 2019, beliau mengabdikan diri sebagai dosen tetap di Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Al Washliyah Labuhanbatu. Dengan keahlian multidisiplin, Shabrina aktif berkontribusi dalam pengembangan ilmu pengetahuan, khususnya dalam linguistik dan pendidikan bahasa Inggris, mencerminkan integritas keilmuan dan visioner.



Samsir, S.T., M.Kom., adalah seorang akademisi dan penulis berpengaruh yang saat ini menjabat sebagai Dekan Fakultas Ilmu Komputer Universitas Alwashliyah (UNIVA). Beliau menyelesaikan gelar Sarjana Teknik di UNIVA dan Magister Komputer dengan konsentrasi Teknik Informasi di Universitas Putra Indonesia "YPTK" Padang. Kini, beliau tengah menempuh studi Doktorat (S3) di Universitas Negeri Padang, Program Studi Pendidikan Teknologi dan Kejuruan. Dengan keahlian mendalam di bidang ilmu komputer, Samsir aktif berkontribusi dalam pengembangan pendidikan teknologi, menggabungkan kecerdasan akademik dengan kepemimpinan yang visioner.



Rina Asriani Levianti, S.E., M.Ak., lahir di Kampung Mesjid, Aceh Barat, pada 17 Juli 1990. Seorang akademisi berkomitmen, beliau menyelesaikan studi S1 dan S2 di Universitas Muhammadiyah Sumatera Utara dengan spesialisasi Akuntansi. Saat ini, Rina mengabdikan diri sebagai dosen di Universitas Al Washliyah Labuhanbatu, membagikan keahliannya selama lebih dari empat tahun. Dengan pendekatan yang mendalam, ia membimbing mahasiswa dalam penguasaan teori dan praktik akuntansi. Dedikasinya dalam dunia pendidikan mencerminkan profesionalisme dan integritas akademik yang tinggi. Untuk kolaborasi, dapat dihubungi melalui rinaasrianilevianti@gmail.com.



Muhammad Rusli, M.S., lahir di Pematang Siantar pada 28 April 1981, adalah seorang akademisi yang mendedikasikan diri pada ranah sastra dengan elegan dan ketelitian ilmiah. Setelah meraih gelar Sarjana (2007) dan Magister Sastra (2012) dalam bidang Sastra Inggris dari Universitas Islam Sumatera Utara, Medan, beliau kini berperan sebagai dosen tetap di Universitas Al Washliyah Labuhanbatu. Dengan wawasan yang luas dan pendekatan yang mendalam, karya-karyanya mencerminkan sintesis antara keilmuan yang rigor dan apresiasi sastra yang bernas. Kehadirannya di dunia akademik memberikan kontribusi berharga bagi pengembangan kajian sastra di Indonesia.



Rizki Lestari, M.Pd. adalah seorang akademisi berdedikasi yang saat ini menjabat sebagai Dosen Pendidikan Bahasa Inggris di Fakultas Keguruan dan Ilmu Pendidikan, Universitas Al Washliyah Labuhanbatu, Sumatera Utara. Lahir di Danau Bale B, Labuhanbatu, ia menyelesaikan pendidikan S1 (2015) dan S2 (2017) di Universitas Sarjanawiyata

Tamansiswa Yogyakarta. Saat ini, ia melanjutkan studi S3 di Universitas Islam Sumatera Utara dengan fokus pada Kajian Bahasa Inggris. Aktif menjalankan Tri Dharma Perguruan Tinggi, Rizki Lestari memiliki komitmen kuat dalam pengembangan pendidikan dan keilmuan. Ia dapat dihubungi melalui surel Rizkilestari2310@gmail.com



Yuannisah Aini Nasution, S.Pd., M.Pd., lahir di Rantauprapat pada 30 Juni 1990, adalah seorang akademisi berkomitmen dalam bidang pendidikan. Menyelesaikan S1 di Universitas Negeri Medan (2012) dan S2 dalam bidang Teknologi Pendidikan (2015) di almamater yang sama. Saat ini, beliau aktif mengabdikan ilmu sebagai tenaga

pengajar di Universitas Al Washliyah Labuhanbatu. Dengan integritas dan dedikasi tinggi, ia terus berkontribusi dalam pengembangan pendidikan melalui riset dan pengajaran yang inspiratif.



Midrawati Hasibuan, S.Pd., M.M., lahir di Rantauprapat, Kabupaten Labuhanbatu, pada 29 Juli 1981, adalah seorang akademisi berdedikasi di bidang manajemen. Saat ini, beliau mengajar di Fakultas Ekonomi, Program Studi Manajemen, Universitas Al Washliyah Labuhanbatu.

Memiliki latar belakang pendidikan yang kuat, beliau menyelesaikan gelar Sarjana Pendidikan Matematika (S.Pd.) dari Universitas Indraprasta PGRI Jakarta (2005) dan Magister Manajemen (M.M.) dari Universitas Islam Jakarta (2012). Sebelum berkarya di perguruan tinggi, beliau pernah mengabdikan diri sebagai guru Matematika di MTs.N 2 Rantauprapat. Dengan pengalaman multidisiplin, beliau menghadirkan perspektif mendalam dalam dunia pendidikan dan manajemen.



Wita Ferwati, M.Pd., adalah seorang akademisi berdedikasi yang lahir di Koto Baru, Sumatera Barat, pada 23 Februari 1989. Ia menyelesaikan gelar Sarjana Pendidikan di Universitas Mahaputra Muhammad Yamin, dengan fokus pada Pendidikan Biologi. Pada tahun 2014, beliau meraih gelar Magister Pendidikan Biologi dari Universitas Negeri Padang.

Saat ini, Wita tengah menempuh studi Doktoral (S3) di Universitas Negeri Medan, dalam bidang Teknologi Pendidikan. Dengan latar belakang akademik yang kuat, ia aktif berkontribusi dalam pengembangan ilmu pendidikan melalui penelitian dan kajian mendalam.



Ibnu Rasyid Munthe, S.T., M.Kom., lahir di Rantau Prapat tahun 1987, adalah seorang akademisi dan praktisi di bidang teknologi informasi yang elegan dan visioner. Setelah menyelesaikan pendidikan S1 di Universitas Nurtanio Bandung dan S2 di Universitas Putra Indonesia (YPTK) Padang, beliau aktif berkontribusi melalui

karya tulis ilmiah dan buku-buku akademik. Saat ini mengajar di Universitas Labuhanbatu, Ibnu juga berinovasi melalui kanal YouTube @manjaddawajada2022 sebagai sarana berbagi pengetahuan, menggabungkan kedalaman

akademis dengan pendekatan pembelajaran yang modern dan mudah diakses. Dedikasinya dalam dunia pendidikan mencerminkan komitmennya untuk mencerdaskan generasi bangsa.



ISBN 978-634-04-2225-2 (PDF)



9

786340

422252