

Analisis Sentimen Pengunduran Menteri Keuangan dan Dampaknya terhadap IHSG dengan *Naive Bayes*

DOI: <http://dx.doi.org/10.35889/jutisi.v15i4.3686>

Creative Commons License 4.0 (CC BY – NC)

**M. Saiful Bahri^{1*}, Mohammad Zainuddin²**

Teknik Informatika, Institut Teknologi dan Bisnis Asia, Malang, Indonesia

*e-mail *Corresponding Author*: msbachriy@gmail.com

Abstract

The resignation of Indonesia's Minister of Finance in 2025 generated substantial public attention on social media and sparked concerns about its possible implications for the Indonesia Composite Stock Price Index (IHSG). This study investigates public sentiment related to the event and evaluates its association with IHSG performance. The analysis utilized 4,655 Twitter/X posts collected between 21 August and 26 September 2025. Public sentiment was classified using the Multinomial Naive Bayes algorithm combined with TF-IDF feature weighting, while the relationship between sentiment indicators and IHSG fluctuations was assessed through Spearman rank correlation and Ordinary Least Squares (OLS) regression. The sentiment classification model demonstrated strong performance, achieving 82.53% accuracy and an AUC value of 0.960. Negative sentiment accounted for the largest proportion of online discussions (46.1%). The results reveal that public sentiment did not exert a significant influence on IHSG movements within the same trading day. However, positive sentiment from the preceding period significantly affected the subsequent day's IHSG log-return ($\beta = 0.0322$; $p = 0.033$), indicating that market reactions to social media sentiment tend to occur with a temporal delay.

Keywords: *Sentiment analysis; IHSG; Naive Bayes; TF-IDF; Social media*

Abstrak

Pengunduran diri Menteri Keuangan Republik Indonesia pada tahun 2025 memicu perhatian luas masyarakat di media sosial dan menimbulkan kekhawatiran mengenai potensi dampaknya terhadap pergerakan Indeks Harga Saham Gabungan (IHSG). Penelitian ini bertujuan menganalisis sentimen publik yang muncul terkait peristiwa tersebut serta mengkaji hubungannya dengan dinamika IHSG. Data penelitian terdiri atas 4.655 unggahan Twitter/X yang dikumpulkan selama periode 21 Agustus hingga 26 September 2025. Analisis sentimen dilakukan menggunakan algoritma Multinomial Naive Bayes dengan pembobotan TF-IDF, sedangkan hubungan antara sentimen dan pergerakan IHSG dianalisis melalui korelasi Spearman dan regresi Ordinary Least Squares (OLS). Hasil pengujian menunjukkan bahwa model klasifikasi memiliki kinerja yang baik dengan tingkat akurasi sebesar 82,53% dan nilai AUC sebesar 0,960. Sentimen negatif mendominasi percakapan publik dengan proporsi 46,1%. Temuan penelitian mengindikasikan bahwa sentimen publik tidak memberikan pengaruh yang signifikan terhadap pergerakan IHSG pada hari perdagangan yang sama. Namun, sentimen positif pada periode sebelumnya terbukti berpengaruh signifikan terhadap log-return IHSG pada hari berikutnya ($\beta = 0,0322$; $p = 0,033$). Hasil ini menunjukkan adanya respons pasar yang tertunda terhadap sentimen publik yang berkembang di media sosial.

Kata kunci: *Analisis sentimen; IHSG; Naive Bayes; TF-IDF; Media Sosial*

1. Pendahuluan

Dinamika pasar keuangan di negara berkembang sangat dipengaruhi oleh faktor-faktor non-ekonomi, termasuk peristiwa politik, kebijakan pemerintah, dan perubahan sentimen publik. Ketidakpastian politik terutama yang berkaitan dengan pergantian pejabat senior di bidang ekonomi telah terbukti memicu volatilitas signifikan di pasar saham, baik di negara maju maupun

negara berkembang [1]. Menteri Keuangan, sebagai arsitek utama kebijakan fiskal dan penjaga kredibilitas fiskal negara, memegang peran strategis yang tak tergantikan dalam membentuk ekspektasi pelaku pasar.

Sebagai salah satu negara dengan kekuatan ekonomi terbesar di Asia Tenggara dan anggota G20, Indonesia menghadapi peristiwa penting pada pertengahan tahun 2025 ketika Sri Mulyani Indrawati memutuskan untuk mengakhiri masa jabatannya sebagai Menteri Keuangan setelah hampir sembilan tahun memimpin kebijakan fiskal nasional. Keputusan tersebut segera menarik perhatian masyarakat luas dan memunculkan berbagai diskusi di media sosial, terutama pada platform Twitter/X yang banyak digunakan sebagai sarana pembentukan dan penyebaran opini publik di era digital. Sebagai media komunikasi global, Twitter/X memberikan ruang bagi pengguna untuk menyampaikan pandangan, respons, serta sentimen terhadap berbagai isu yang sedang berkembang. Informasi yang terekam pada platform ini sering dimanfaatkan sebagai sumber data analisis sentimen karena tersedia secara cepat dan mencerminkan reaksi publik secara langsung [2]. Selain itu, penyebaran informasi melalui media sosial berlangsung sangat cepat dan dapat menjangkau pelaku pasar keuangan di berbagai negara, sehingga berpotensi memengaruhi persepsi investor dan keputusan investasi [3]. Namun demikian, respons pasar terhadap informasi tersebut umumnya tidak terjadi secara instan karena dipengaruhi oleh proses interpretasi dan evaluasi yang dilakukan oleh masing-masing pelaku pasar.

Dalam melakukan investasi di pasar modal, investor memanfaatkan berbagai sumber informasi untuk memahami kondisi dan pergerakan saham, mulai dari situs resmi Bursa Efek Indonesia (BEI), perusahaan sekuritas, media massa, hingga platform digital seperti Twitter/X [4]. Seiring berkembangnya teknologi kecerdasan buatan (*Artificial Intelligence/AI*) dan pemrosesan bahasa alami (*Natural Language Processing/NLP*), muncul berbagai metode yang memungkinkan pengukuran sentimen publik dilakukan secara otomatis, cepat, dan terstruktur [5]. Salah satu pendekatan yang banyak digunakan adalah klasifikasi teks berbasis *machine learning* untuk mengidentifikasi kecenderungan opini dalam data digital. Di antara berbagai algoritma yang tersedia, *Multinomial Naive Bayes* banyak dipilih karena memiliki efisiensi komputasi yang baik serta mampu menangani data teks dalam jumlah besar secara efektif, khususnya data yang berasal dari media sosial [6]. Kinerja metode ini dapat ditingkatkan melalui penggunaan pembobotan *Term Frequency-Inverse Document Frequency* (TF-IDF), yang membantu menghasilkan representasi fitur teks yang lebih informatif dan meningkatkan akurasi klasifikasi sentimen [7]. Pendekatan tersebut relevan diterapkan pada teks berbahasa Indonesia yang memiliki karakteristik bahasa informal, penggunaan slang, dan variasi linguistik yang tinggi dalam interaksi media sosial.

Berbagai penelitian sebelumnya telah mengkaji hubungan antara sentimen media sosial dan pergerakan pasar saham. Ranco et al. (2016) [8] melaporkan bahwa sentimen yang diekspresikan pengguna Twitter memiliki keterkaitan dengan abnormal return dan aktivitas perdagangan saham perusahaan berskala besar di pasar internasional. Penelitian Pagolu et al. (2016) [9] juga menemukan bahwa analisis sentimen Twitter mampu memprediksi arah pergerakan pasar saham menggunakan pendekatan *machine learning*. Selanjutnya, Hu et al. (2018) [10] membuktikan bahwa integrasi data media sosial dengan model *deep learning* dapat meningkatkan kemampuan prediksi volatilitas pasar saham secara signifikan.

Meskipun demikian, masih terbatasnya penelitian yang menghubungkan sentimen media sosial dengan pergerakan IHSG dalam konteks peristiwa politik-ekonomi di Indonesia. Sebagian besar studi sebelumnya berfokus pada analisis sentimen umum tanpa mengaitkannya secara langsung dengan dinamika pasar modal. Selain itu, integrasi pendekatan NLP dan analisis ekonometrika untuk mengkaji dampak sentimen publik terhadap pasar saham Indonesia masih jarang dilakukan. Oleh karena itu, diperlukan penelitian yang mampu menjelaskan hubungan antara sentimen media sosial dan respons pasar saham secara empiris.

Atas dasar fenomena dan kajian yang telah diuraikan, penelitian ini bertujuan untuk: (1) membangun model klasifikasi sentimen Twitter berbahasa Indonesia menggunakan TF-IDF dan *Multinomial Naive Bayes*; (2) menganalisis distribusi sentimen publik terkait pengunduran diri Menteri Keuangan; (3) menguji hubungan sentimen publik dengan pergerakan IHSG, termasuk efek keterlambatan (*lag effect*); serta (4) memberikan kontribusi bagi pengembangan analisis sentimen keuangan berbasis NLP dan *machine learning* pada pasar modal Indonesia.

2. Metodologi

2.1 Sumber Data

Sumber data penelitian terdiri atas data teks dari Twitter/X dan data pasar modal. Data Twitter/X dikumpulkan melalui API resmi menggunakan kata kunci yang berkaitan dengan pengunduran diri Menteri Keuangan, seperti *Sri Mulyani*, *Menkeu*, *menteri keuangan*, *IHSG*, dan istilah terkait lainnya. Pengumpulan data dilakukan pada periode 21 Agustus–26 September 2025 dan menghasilkan 4.655 cuitan berbahasa Indonesia. Data pasar modal berupa data harian IHSG (*Open, High, Low, Close, Volume*) diperoleh dari Bursa Efek Indonesia (BEI) pada periode yang sama. Twitter/X dipilih karena merupakan media yang aktif digunakan untuk mendiskusikan isu ekonomi dan pasar modal serta menyediakan data publik yang dapat diakses secara sistematis.

2.2 Tahapan Pra-Pemrosesan Teks

Pra-pemrosesan teks merupakan tahap kritis yang menentukan kualitas fitur yang digunakan oleh model klasifikasi. Penelitian ini menerapkan sepuluh tahapan pra-pemrosesan secara berurutan, sebagaimana dirangkum dalam Tabel 1.

Tabel 1. Tahapan Pra-Pemrosesan Teks

Tahap Pra-Pemrosesan	Data Sebelum	Data Sesudah	Berkurang	Keterangan
Cleaning (UL, mention, hashtag, angka)	4.655	4.655	0	Normalisasi karakter khusus
Penghapusan teks kosong	4.655	4.627	28	Tweet tanpa konten teks
Penghapusan duplikat	4.627	4.349	278	Tweet identik dihapus
Case folding	4.349	4.349	0	Konversi ke huruf kecil
Normalisasi bahasa informal	4.349	4.349	0	Penyeragaman kata slang/singkatan
Tokenisasi	4.349	4.349	0	Pemecahan teks menjadi token
Penghapusan stopword	4.349	4.349	0	Menggunakan daftar stopword Bahasa Indonesia
Stemming (Sastrawi)	4.349	4.349	0	Pemotongan afiks Bahasa Indonesia
Drop token 1 huruf	4.349	4.349	0	Hapus token berkarakter tunggal
Drop hasil stemming kosong	4.349	4.348	1	Hapus teks yang kosong pasca stemming

Setelah seluruh tahapan pra-pemrosesan diterapkan, sebanyak 4.348 dokumen tersisa dan siap digunakan pada proses pelabelan serta pengembangan model klasifikasi. Penerapan algoritma stemmer Sastrawi yang dirancang khusus untuk Bahasa Indonesia memungkinkan proses normalisasi kata ke bentuk dasar dilakukan secara akurat sesuai dengan kaidah morfologi bahasa tersebut.

2.3 Pelabelan Sentimen (*Labeling*)

Proses pelabelan sentimen dilakukan menggunakan pendekatan berbasis leksikon dengan menggabungkan kamus sentimen Bahasa Indonesia dan leksikon khusus bidang keuangan yang disusun untuk kebutuhan penelitian ini. Setiap cuitan kemudian dikelompokkan ke dalam tiga kategori sentimen, yaitu positif, negatif, dan netral. Untuk memastikan kualitas pelabelan, sebanyak 10% data dipilih secara acak dan dievaluasi oleh dua anotator independen. Tingkat kesepakatan keduanya diukur menggunakan koefisien Cohen's Kappa dan menghasilkan nilai 0,82, yang menunjukkan tingkat kesepakatan sangat tinggi (*almost perfect agreement*) [11]. Temuan tersebut mengindikasikan bahwa proses pelabelan memiliki reliabilitas yang kuat dan konsistensi yang baik.

2.4 Distribusi Data dan Pembagian Dataset

Hasil pelabelan menghasilkan 2.003 data negatif (46,1%), 1.238 data positif (28,5%), dan 1.107 data netral (25,5%), yang menunjukkan dominasi sentimen negatif selama peristiwa pengunduran diri Menteri Keuangan. Pembagian dataset dilakukan menggunakan *stratified random sampling* pada rasio 80:20, sehingga diperoleh 3.478 data latih dan 870 data uji dengan keseimbangan distribusi kelas yang tetap terjaga pada kedua kelompok data.

2.5 Representasi Fitur TF-IDF

Dalam penelitian ini, proses klasifikasi sentimen dilakukan dengan menerapkan algoritma Multinomial Naive Bayes (MNB) karena memiliki efisiensi komputasi yang tinggi dan performa yang baik pada klasifikasi teks berdimensi besar [12]. Untuk meningkatkan kualitas representasi teks, MNB dikombinasikan dengan metode *Term Frequency–Inverse Document Frequency* (TF-IDF) yang memberikan bobot lebih tinggi pada kata-kata yang bersifat diskriminatif dalam korpus. Kombinasi TF-IDF dan Naive Bayes telah terbukti menghasilkan akurasi yang kompetitif pada berbagai penelitian analisis sentimen [13].

Sebelum tahap klasifikasi, data diproses melalui normalisasi kata, penghapusan stopwords, dan stemming berbasis Sastrawi untuk memperbaiki representasi teks serta meningkatkan performa model [14]. Perhitungan bobot TF-IDF mengacu pada Persamaan (1), sedangkan nilai IDF dihitung menggunakan Persamaan (2).

$$\text{TF-IDF}(t,d) = \text{TF}(t,d) \times \text{IDF}(t) \dots\dots\dots(1)$$

$$\text{IDF}(t) = \log(N / (1 + \text{df}(t))) + 1 \dots\dots\dots(2)$$

N menyatakan jumlah total dokumen, sedangkan $\text{df}(t)$ menunjukkan jumlah dokumen yang memuat term t . Hasil vektorisasi membentuk matriks TF-IDF berukuran 4.348×3.564 , dengan seleksi fitur menggunakan $\text{min_df} = 2$ dan $\text{max_df} = 0,95$ untuk mengurangi noise serta meningkatkan generalisasi model.

2.6 Algoritma Multinomial Naive Bayes

Multinomial Naive Bayes (MNB) digunakan sebagai model klasifikasi sentimen karena memiliki efisiensi dan performa yang baik pada data teks berdimensi tinggi [15]. Metode ini bekerja berdasarkan Teorema Bayes dengan asumsi independensi antar fitur kata. Probabilitas posterior dokumen terhadap suatu kelas dihitung menggunakan:

$$P(c|d) = \frac{(P(d|c)P(c))}{P(d)} \dots\dots\dots(3)$$

Pada persamaan tersebut, $(P(c|d))$ menunjukkan probabilitas posterior bahwa dokumen (d) termasuk ke dalam kelas (c). Sementara itu, $(P(d|c))$ merepresentasikan peluang kemunculan dokumen (d) apabila diketahui berasal dari kelas (c). Notasi $(P(c))$ mengacu pada probabilitas awal (*prior probability*) dari kelas (c), sedangkan $(P(d))$ menyatakan probabilitas keseluruhan dari dokumen (d) yang diamati.

Pada MNB, probabilitas kemunculan term dihitung berdasarkan frekuensi kata dengan teknik *Laplace smoothing* untuk menghindari probabilitas nol:

$$P(w_i|c) = \frac{(\text{count}(w_i, c) + 1)}{(\sum \text{count}(w, c) + |V|)} \dots\dots\dots(4)$$

Keterangan:

$\text{count}(w_i, c)$ merupakan jumlah kemunculan kata w_i pada kelas c ,

$|V|$ merupakan jumlah kosakata (*vocabulary*),

penambahan nilai 1 merupakan teknik *Laplace smoothing* untuk menghindari probabilitas nol.

Sebelum proses klasifikasi, data menjalani tahap pra-pemrosesan yang mencakup *case folding*, tokenisasi, normalisasi, penghapusan *stopword*, dan stemming menggunakan Sastrawi [16]. Model dibangun dengan scikit-learn 1.3.0 pada Python 3.10 ($\alpha = 1,0$). Dataset dibagi menggunakan *stratified random sampling* dengan rasio 80:20, sedangkan kinerja model dievaluasi berdasarkan *accuracy*, *precision*, *recall*, *F1-score*, dan AUC.

2.7 Evaluasi Model Klasifikasi

Evaluasi model dilakukan untuk menilai kemampuan *Multinomial Naive Bayes* dalam mengklasifikasikan sentimen ke dalam kategori positif, negatif, dan netral. Pengujian menggunakan 20% data uji yang diperoleh melalui stratified random sampling guna mempertahankan proporsi masing-masing kelas sentimen.

Kinerja model diukur menggunakan *confusion matrix*, *accuracy*, *precision*, *recall*, *F1-score*, dan AUC. Penggunaan berbagai metrik diperlukan karena data sentimen media sosial umumnya memiliki distribusi kelas yang tidak seimbang, sehingga akurasi saja belum cukup menggambarkan performa model secara komprehensif [17].

Nilai akurasi dihitung menggunakan persamaan berikut:

$$Accuracy = \frac{(TP + TN)}{(TP + TN + FP + FN)} \dots\dots\dots(5)$$

TP menunjukkan jumlah prediksi positif yang benar (*True Positive*), *TN* merupakan prediksi negatif yang benar (*True Negative*), *FP* adalah prediksi positif yang keliru (*False Positive*), dan *FN* menunjukkan prediksi negatif yang salah (*False Negative*).

Nilai *precision* menunjukkan proporsi prediksi yang benar pada suatu kelas tertentu dan dirumuskan sebagai berikut:

$$Precision = \frac{\{TP\}}{\{TP + FP\}} \dots\dots\dots(6)$$

Nilai *recall* menggambarkan tingkat keberhasilan model dalam mengenali seluruh anggota suatu kelas dan dinyatakan melalui persamaan berikut:

$$Recall = \frac{\{TP\}}{\{TP + FN\}} \dots\dots\dots(7)$$

Sebagai ukuran yang mengakomodasi *precision* dan *recall* secara bersamaan, *F1-score* dihitung menggunakan persamaan berikut:

$$F1\{-\}Score = 2 \times \frac{\{Precision \times Recall\}}{\{Precision + Recall\}} \dots\dots\dots(8)$$

Selain *accuracy*, penelitian ini juga menggunakan AUC dengan pendekatan One-vs-Rest untuk menilai kemampuan model dalam membedakan kelas sentimen. Nilai AUC yang semakin mendekati 1 menunjukkan performa klasifikasi yang lebih baik [18]. Seluruh proses pelatihan dan evaluasi dilakukan menggunakan scikit-learn 1.3.0 pada Python 3.10 dengan parameter $\alpha = 1,0$ sebagai *Laplace smoothing* untuk menghindari probabilitas nol.

2.8 Pengukuran Sentimen dan Analisis Pengaruh terhadap IHSG

Untuk setiap tanggal perdagangan, dilakukan agregasi sentimen dengan menghitung rasio sentimen positif (*pos_ratio*) dan rasio sentimen negatif (*neg_ratio*) dari keseluruhan cuitan pada hari yang bersangkutan. Skor sentimen komposit dihitung sebagai *pos_ratio - neg_ratio*. Data IHSG dikonversi menjadi log-return harian untuk memastikan stasionaritas deret waktu.

Analisis statistik dilakukan dalam tiga tahap: (1) Uji normalitas dengan metode Shapiro-Wilk; (2) Uji korelasi menggunakan *Spearman Rank Correlation* (dipilih karena data tidak terdistribusi normal); (3) Analisis regresi linear OLS (*Ordinary Least Squares*) untuk menguji pengaruh simultan variabel sentimen terhadap log-return IHSG, baik tanpa lag (Model A) maupun dengan lag satu periode (Model B). Semua analisis statistik dilakukan menggunakan level signifikansi $\alpha = 0,05$.

3. Hasil dan Pembahasan

3.1 Hasil


1) Karakteristik Data dan Distribusi Sentimen

Dari total 4.655 cuitan yang berhasil dikumpulkan, setelah melalui serangkaian tahapan pra-pemrosesan, tersisa 4.348 cuitan yang valid untuk analisis lebih lanjut. Reduksi data sebesar 307 cuitan (6,6%) terutama disebabkan oleh penghapusan duplikat (278 cuitan) dan penghapusan teks kosong (28 cuitan). Hal ini mengindikasikan adanya aktivitas retweet dan duplikasi konten yang cukup tinggi, yang umum terjadi pada topik yang viral di Twitter.

Analisis frekuensi kata kunci menunjukkan bahwa istilah "srimulyani" muncul paling dominan dengan frekuensi 4.412 kali, diikuti "menteri" (1.970 kali), "ihsg" (968 kali), "ekonomi" (719 kali), dan "purbayayudhisadewa" (658 kali) nama pengganti Menteri Keuangan. Kata-kata terkait pergerakan pasar seperti "rupiah" (416 kali), "saham" (457 kali), dan topik kebijakan seperti "pajak" (300 kali), "kebijakan" (237 kali) juga cukup dominan, mengindikasikan tingginya relevansi topik dengan isu keuangan publik.


Distribusi kelas sentimen didominasi oleh sentimen negatif sebesar 46,1% (2.003 cuitan), diikuti positif 28,5% (1.238 cuitan), dan netral 25,5% (1.107 cuitan). Dominasi sentimen negatif mencerminkan kekhawatiran publik terhadap implikasi pergantian Menteri Keuangan, dengan tema dominan pada kata kerja "ganti", "mundur", "turun", dan "jabat" yang muncul secara berulang dalam cuitan bersentimen negatif.

Gambar 4.1 Distribusi Kelas Sentimen Twitter (n = 4.348)



Gambar 1. Distribusi Kelas Sentimen Twitter (n = 4.348)

Gambar 4.2 Frekuensi 10 Kata Tertinggi Sebelum dan Sesudah Pra-pemrosesan



Gambar 2. Frekuensi 10 Kata Tertinggi Sebelum dan Sesudah Pra-pemrosesan

2) Kinerja Model Klasifikasi *Naive Bayes*


Model *Naive Bayes* yang dikombinasikan dengan TF-IDF mencapai akurasi keseluruhan sebesar 82,53% pada data uji. Kosakata model berjumlah 3.564 fitur unik setelah proses filtering. Tabel 2 menyajikan laporan klasifikasi lengkap per kelas.

Tabel 2. Laporan Klasifikasi Model *Naive Bayes* (n=870 data uji)

Kelas Sentimen	Presisi	Recall	F1-Score	Support
Negatif	77,87%	96,51%	86,19%	401
Netral	87,56%	79,64%	83,41%	221
Positif	90,12%	62,50%	73,81%	248
Accuracy	82,53%	82,53%	82,53%	870
Macro Average	85,18%	79,55%	81,14%	870
Weighted Average	83,82%	82,53%	81,96%	870


Kurva ROC dengan nilai AUC = 0,960 mengindikasikan kemampuan diskriminasi model yang sangat baik (*excellent*) menurut kriteria Hosmer & Lemeshow (2000) [19], yang mengklasifikasikan AUC di atas 0,90 sebagai model yang *excellent*. Model menunjukkan *recall* tertinggi pada kelas negatif (96,51%), yang berarti hampir semua cuitan bersentimen negatif berhasil diidentifikasi dengan benar. Sebaliknya, kelas positif memiliki *recall* terendah (62,50%), mengindikasikan bahwa sejumlah cuitan positif diklasifikasikan secara keliru, terutama sebagai kelas negatif, sebagaimana terlihat dari confusion matrix (75 kesalahan klasifikasi positif sebagai negatif).

Gambar 4.3 Kinerja Klasifikasi Model Naive Bayes



Gambar 3. Kinerja Klasifikasi Naive Bayes: Precision, Recall, F1, dan Confusion Matrix

Gambar 4.4 Kurva ROC - Naive Bayes (AUC = 0,960)




Gambar 4. Kurva ROC Naive Bayes (AUC = 0,960)

Analisis confusion matrix menunjukkan bahwa model bekerja paling baik untuk mengidentifikasi sentimen negatif (387 dari 401 benar, atau 96,5%), sedangkan untuk kelas positif terdapat tantangan lebih besar akibat tumpang tindih leksikal antara cuitan yang mengkritik secara keras (negatif) dengan yang mengekspresikan harapan positif menggunakan kata-kata bernada kritis, suatu fenomena linguistik yang umum dalam wacana politik Bahasa Indonesia.

3) Uji Normalitas

Hasil uji Shapiro-Wilk menunjukkan bahwa variabel *pos_ratio* ($W=0,8526$; $p=0,0020$) dan *neg_ratio* ($W=0,8954$; $p=0,0146$) tidak berdistribusi normal ($p < 0,05$). Sebaliknya, variabel *log_return IHSG* ($W=0,9407$; $p=0,1535$) berdistribusi normal ($p > 0,05$). Karena tidak seluruh variabel memenuhi asumsi normalitas, analisis korelasi dilakukan menggunakan Spearman Rank Correlation yang lebih robust terhadap pelanggaran asumsi distribusi normal.

Gambar 4.5 Uji Normalitas Shapiro-Wilk dan Korelasi Spearman



Gambar 5. Uji normalitas Shapiro-Wilk dan Korelasi Spearman Sentimen vs IHSG

4) Uji Korelasi Spearman

Hasil pengujian korelasi Spearman antara variabel sentimen dan log-return IHSG disajikan pada Tabel 3.

Tabel 3. Uji Korelasi Spearman Sentimen vs. Log-Return IHSG

Pasangan Variabel	Koefisien Korelasi (r)	P-Value	Keterangan
pos_ratio ↔ log_return	0,1991	0,3400	Tidak Signifikan
neg_ratio ↔ log_return	-0,1878	0,3686	Tidak Signifikan
pos_ratio_lag1 ↔ log_return	0,3976	0,0544	Mendekati Signifikan
neg_ratio_lag1 ↔ log_return	-0,1732	0,4183	Tidak Signifikan

Korelasi langsung antara sentimen dan IHSG bersifat lemah dan tidak signifikan secara statistik. Namun, sentimen positif pada periode sebelumnya (pos_ratio_lag1) menunjukkan korelasi yang cukup kuat dan mendekati signifikansi ($r=0,3976$; $p=0,0544$), di mana nilai p yang hanya sedikit melebihi ambang batas 0,05 menunjukkan tendensi yang patut diperhatikan.

5) Analisis Regresi OLS

Hasil regresi OLS menunjukkan bahwa sentimen publik tidak berpengaruh signifikan terhadap pergerakan IHSG pada hari yang sama. Pada Model A (tanpa lag), nilai R^2 sebesar 0,060 menunjukkan bahwa variabel sentimen hanya mampu menjelaskan 6,0% variasi log-return IHSG. Selain itu, model tidak signifikan secara statistik ($F = 0,6967$; $p = 0,509$), dan baik variabel *pos_ratio* ($p = 0,286$) maupun *neg_ratio* ($p = 0,744$) tidak memiliki pengaruh yang signifikan.


Sebaliknya, Model B yang memasukkan sentimen dengan lag satu periode menunjukkan peningkatan kemampuan penjelasan model. Nilai R^2 meningkat menjadi 0,232, yang berarti model mampu menjelaskan 23,2% variasi log-return IHSG. Sentimen positif periode sebelumnya berpengaruh signifikan terhadap log-return IHSG, sedangkan sentimen negatif tidak. Temuan ini menunjukkan adanya *lag effect* dalam respons pasar terhadap sentimen publik. Ringkasan hasil regresi disajikan pada Tabel 4.

Tabel 4. Perbandingan Hasil Regresi OLS Model A (Tanpa Lag) dan Model B (Dengan Lag-1)

Parameter	Model A (Tanpa Lag)	Model B (Dengan Lag-1)
R^2	0,060	0,232
Adj. R^2	-0,026	0,159
F-statistik	0,6967	3,167
Prob (F-statistik)	0,509 (n.s.)	0,0628 (~sig.)
β_0 (konstanta)	-0,0051 ($p=0,544$)	-0,0088 ($p=0,261$)
β_1 (pos_ratio / lag1)	0,0165 ($p=0,286$)	0,0322 ($p=0,033^*$)
β_2 (neg_ratio / lag1)	0,0033 ($p=0,744$)	0,0047 ($p=0,615$)
Durbin-Watson	1,750	2,073
N Observasi	25	24

Nilai Durbin-Watson sebesar 2,073 menunjukkan tidak adanya autokorelasi serial pada residual Model B. Selain itu, hasil uji diagnostik menunjukkan residual berdistribusi mendekati normal (*Jarque-Bera* $p = 0,725$), sehingga asumsi dasar regresi terpenuhi dan hasil estimasi dapat diinterpretasikan secara memadai. Perbandingan antara nilai aktual dan prediksi log-return IHSG

pada Model B ditampilkan pada Gambar 6.



Gambar 6. Perbandingan Nilai Aktual dan Prediksi Log-Return IHSG Model B (regresi lag-1)

3.2 Pembahasan

1) Kinerja Model Klasifikasi dan Implikasi Metodologis

Model *Multinomial Naive Bayes* dengan TF-IDF menghasilkan akurasi 82,53% dan AUC 0,960, menunjukkan kemampuan yang sangat baik dalam mengklasifikasikan sentimen pada data Twitter/X berbahasa Indonesia meskipun karakteristik datanya cukup kompleks. Tingginya performa model menunjukkan bahwa kombinasi tahapan *preprocessing* yang komprehensif, meliputi normalisasi bahasa informal, penghapusan *stopword*, dan proses *stemming* menggunakan Sastrawi, efektif meningkatkan kualitas representasi teks sehingga model lebih mampu mengenali pola sentimen. Hasil penelitian ini sejalan dengan Kurniasih dan Setyawan (2022), yang menegaskan bahwa *preprocessing* yang optimal dapat meningkatkan akurasi dan kinerja analisis sentimen pada teks media sosial berbahasa Indonesia [20].

AUC yang tinggi mencerminkan kemampuan model dalam membedakan kategori sentimen secara efektif. Meskipun dataset tidak seimbang, performa klasifikasi *Multinomial Naive Bayes* tetap terjaga dengan baik.

Kesalahan klasifikasi yang ditemukan umumnya terjadi ketika sentimen positif dikategorikan sebagai negatif. Fenomena ini berkaitan dengan karakteristik komunikasi politik di media sosial Indonesia yang sering memanfaatkan kritik implisit, satire, atau optimisme yang dibingkai dalam konteks kekhawatiran ekonomi. Ambiguitas semantik semacam ini merupakan tantangan umum dalam analisis sentimen politik berbasis *machine learning* [21].

Nilai *recall* yang tinggi pada kelas negatif (96,51%) menunjukkan kemampuan model yang sangat baik dalam mengenali sentimen negatif. Temuan ini berpotensi dimanfaatkan sebagai sistem peringatan dini terhadap gejolak pasar, mengingat investor umumnya lebih responsif terhadap informasi negatif dibandingkan informasi positif akibat fenomena *loss aversion* [22].

2) Ketiadaan Pengaruh Langsung Sentimen terhadap IHSG

Hasil analisis menunjukkan bahwa sentimen media sosial tidak memiliki pengaruh signifikan terhadap pergerakan IHSG pada hari yang sama. Temuan ini terlihat dari nilai R² yang rendah pada Model A (0,060) serta tingkat signifikansi yang tidak memenuhi kriteria statistik ($p = 0,509$), sehingga perubahan sentimen di Twitter/X tidak secara langsung diikuti oleh perubahan harga saham.

Berdasarkan perspektif *Efficient Market Hypothesis* (EMH), hasil ini menunjukkan bahwa pasar kemungkinan telah merespons informasi mengenai pengunduran diri Menteri Keuangan sebelum sentimen tersebut menyebar luas di media sosial. Dalam pasar yang bersifat semi-kuat, harga saham cenderung menyesuaikan dengan cepat terhadap informasi publik yang relevan, sehingga sentimen media sosial lebih mencerminkan opini masyarakat daripada menjadi faktor yang secara langsung menentukan pergerakan harga saham.

Lemahnya pengaruh sentimen terhadap IHSG juga dapat dijelaskan oleh dominasi investor institusional di pasar modal Indonesia. Berdasarkan *noise trading theory*, keputusan investasi investor institusional lebih banyak didasarkan pada fundamental ekonomi, prospek kebijakan fiskal, laporan keuangan, dan stabilitas makroekonomi dibandingkan opini jangka pendek yang berkembang di media sosial [23]. Kondisi ini menyebabkan fluktuasi sentimen publik di Twitter/X tidak secara langsung menghasilkan perubahan signifikan pada IHSG.

Temuan ini menegaskan bahwa pengaruh sentimen media sosial terhadap pasar saham perlu dipahami dalam konteks struktur pasar dan karakteristik investor. Dampaknya kemungkinan lebih terlihat pada saham-saham tertentu yang sensitif terhadap isu politik atau didominasi oleh investor ritel dibandingkan pada indeks agregat seperti IHSG.

3) Pengaruh Sentimen Positif Lag-1 terhadap IHSG

Analisis menunjukkan bahwa sentimen positif pada periode sebelumnya (pos_ratio_lag1) berkontribusi signifikan terhadap peningkatan log-return IHSG pada periode berikutnya ($\beta = 0,0322$; $p = 0,033$; $R^2 = 0,232$). Hasil ini mengindikasikan bahwa optimisme yang terbentuk di media sosial tidak langsung memengaruhi pasar pada hari yang sama, melainkan memerlukan waktu untuk diterjemahkan menjadi keputusan investasi.

Dari perspektif *investor sentiment theory*, sentimen positif pada hari t mencerminkan optimisme investor yang belum sepenuhnya terwujud dalam aktivitas perdagangan, karena proses pembentukan opini hingga eksekusi transaksi membutuhkan waktu. Sementara itu, *information diffusion theory* menjelaskan bahwa informasi yang tersebar di Twitter memerlukan waktu untuk menjangkau berbagai segmen investor dan diproses menjadi sinyal perdagangan yang terkoordinasi [24].

Hasil penelitian ini konsisten dengan temuan yang dilaporkan oleh Sina et al. (2023) yang menemukan bahwa *Twitter mood* pada hari $t-1$ memiliki kemampuan prediktif terhadap return saham pada hari t [25]. Peningkatan rasio sentimen positif diperkirakan akan mendorong kenaikan log-return IHSG pada hari berikutnya, sehingga sentimen positif dapat dipandang sebagai indikator optimisme pasar.

Dalam konteks pengunduran diri Sri Mulyani, sentimen positif umumnya mencerminkan kepercayaan terhadap stabilitas kebijakan fiskal, kesinambungan ekonomi nasional, dan figur pengganti Menteri Keuangan. Optimisme tersebut kemudian tercermin dalam peningkatan kepercayaan investor dan pemulihan IHSG pada periode perdagangan berikutnya. Nilai R^2 sebesar 0,232 menunjukkan bahwa sentimen media sosial memiliki kemampuan moderat dalam menjelaskan variasi pergerakan IHSG, sekaligus mengonfirmasi potensinya sebagai *alternative market signal* dalam analisis pasar modal modern [26].

4) Tidak Signifikannya Pengaruh Sentimen Negatif

Berbeda dengan sentimen positif, sentimen negatif tidak menunjukkan pengaruh signifikan terhadap IHSG, baik secara langsung maupun melalui pendekatan *lag*. Temuan ini menarik karena secara teoritis informasi negatif umumnya memiliki dampak psikologis yang lebih kuat terhadap investor dibandingkan informasi positif.

Salah satu penjelasan yang mungkin adalah bahwa respons pasar terhadap informasi negatif terjadi sangat cepat dalam skala *intraday*, sehingga tidak sepenuhnya tertangkap oleh data harian yang digunakan dalam penelitian. Investor cenderung segera melakukan aksi jual untuk menghindari kerugian, sehingga dampak sentimen negatif kemungkinan hanya berlangsung dalam waktu yang relatif singkat.

Selain itu, mekanisme stabilisasi pasar oleh investor institusional dan lembaga keuangan negara dapat meredam tekanan jual yang dipicu oleh sentimen negatif. Peran sebagai *market stabilizer* tersebut membantu menjaga stabilitas pasar sehingga peningkatan sentimen negatif di media sosial tidak secara langsung tercermin pada pergerakan IHSG.

Dominasi sentimen negatif dalam dataset juga berpotensi menimbulkan *saturation effect*. Ketika mayoritas percakapan publik telah bernada negatif, tambahan sentimen negatif baru tidak lagi memberikan informasi yang cukup kuat untuk mengubah perilaku investor karena kondisi tersebut telah dianggap sebagai sesuatu yang telah diperhitungkan pasar (*priced-in condition*). Akibatnya, peningkatan sentimen negatif tidak menghasilkan perubahan signifikan pada pergerakan IHSG.

5) Implikasi Kebijakan dan Praktis

Secara teoretis, penelitian ini memperkuat perspektif *behavioral finance* yang menempatkan sentimen publik sebagai faktor yang berkaitan dengan dinamika pasar keuangan, serta menunjukkan bahwa media sosial dapat berfungsi sebagai sumber informasi alternatif dalam menjelaskan perilaku investor.

Dari sisi metodologis, integrasi NLP, TF-IDF, dan Multinomial Naive Bayes terbukti efektif untuk klasifikasi sentimen pada data media sosial berbahasa Indonesia dan berpotensi

dikembangkan sebagai sistem analisis sentimen otomatis untuk pasar modal maupun pemantauan sentimen publik yang dapat dipantau secara langsung.

Dalam praktiknya, sentimen media sosial, khususnya peningkatan sentimen positif pada hari sebelumnya, dapat dimanfaatkan investor sebagai *leading indicator* untuk memprediksi arah pasar jangka pendek dan mendukung pengambilan keputusan investasi. Bagi regulator seperti OJK dan BEI, analisis sentimen berbasis AI berpotensi digunakan sebagai *early warning system* untuk mendeteksi potensi gejolak pasar selama periode ketidakpastian politik dan ekonomi.

Selain itu, penelitian ini membuka peluang studi lanjutan dengan memanfaatkan data *intraday* atau *high-frequency trading*, serta mengintegrasikan pendekatan *deep learning*, *transformer-based NLP*, dan analisis jaringan sosial guna meningkatkan akurasi prediksi dan pemahaman terhadap perilaku investor digital.

4. Simpulan

Hasil penelitian menunjukkan bahwa model klasifikasi sentimen berbasis Naive Bayes dan TF-IDF mampu mengklasifikasikan data Twitter berbahasa Indonesia secara efektif, dengan akurasi 82,53% dan nilai AUC mencapai 0,960. Hasil analisis menunjukkan bahwa sentimen negatif mendominasi percakapan publik (46,1%), mencerminkan kekhawatiran terhadap dampak pergantian Menteri Keuangan terhadap stabilitas ekonomi nasional.

Analisis korelasi dan regresi menunjukkan bahwa sentimen publik tidak berpengaruh langsung terhadap pergerakan IHSG. Namun, sentimen positif pada periode sebelumnya (lag-1) berpengaruh signifikan terhadap log-return IHSG hari berikutnya ($\beta = 0,0322$; $p = 0,033$), yang mengindikasikan adanya keterlambatan respons pasar terhadap sentimen publik. Temuan ini mendukung teori perilaku keuangan dan difusi informasi.

Secara teoretis, penelitian ini memvalidasi pengaruh investor sentiment lag pada pasar modal Indonesia serta menunjukkan efektivitas integrasi NLP dan analisis ekonometrik dalam studi sentimen-pasar. Secara praktis, hasil penelitian mendukung pengembangan sistem pemantauan sentimen berbasis AI sebagai alat deteksi dini volatilitas pasar.

Keterbatasan penelitian meliputi ukuran sampel *time series* yang relatif kecil, penggunaan data harian, fokus pada Twitter sebagai satu-satunya sumber sentimen, serta penggunaan *Naive Bayes* yang belum mampu menangkap konteks semantik secara mendalam. Penelitian selanjutnya disarankan menggunakan data multi-platform, periode observasi yang lebih panjang, data berfrekuensi tinggi, serta model berbasis *deep learning* atau *transformer* untuk meningkatkan akurasi dan kemampuan prediksi.

Daftar Referensi

- [1] J. Darby and G. Roy, "Political uncertainty and stock market volatility: New evidence from the 2014 Scottish Independence Referendum," *Scottish Journal of Political Economy*, vol. 66, no. 4, pp. 525–546, 2019.
- [2] E. Setiadi and D. A. Sulisty, "Analisis sentimen kebijakan makan bergizi gratis menggunakan IndoBERT dan machine learning," *JURNAL FASILKOM*, vol. 15, no. 3, pp. 507–513, Dec. 2025, doi: 10.37859/jf.v15i3.10546.
- [3] S. Budiarta, "Pengaruh indeks kawasan regional tetangga (STI, ASX200, KLSE, dan VN) terhadap indeks saham gabungan Indonesia (IHSG) di Bursa Efek Indonesia (BEI)," *Jurnal Ekonomi Manajemen dan Bisnis (JUBIS)*, vol. 2, no. 2, pp. 43–55, 2021. [Online]. Available: JUBIS ITB Asia Malang
- [4] Santo, "Variabel-variabel rasio keuangan yang mempengaruhi harga saham emiten yang terdapat pada indeks SRI KEHATI di Bursa Efek Indonesia," *Jurnal Ekonomi Manajemen dan Bisnis (JUBIS)*, vol. 3, no. 2, 2022. [Online]. Available: JUBIS Institut Teknologi dan Bisnis Asia Malang
- [5] H. H. Kurniawan and D. Wardana, "Peran perceived value, technological readiness, dan cost-benefit analysis pada adopsi fitur premium artificial intelligence oleh kalangan pelaku bisnis Surabaya," *JPRO: Jurnal Manajemen dan Profesional*, vol. 5, no. 1, pp. 166–182, Jul. 2024.
- [6] V. A. Kharde and S. S. Sonawane, "Sentiment analysis of Twitter data: A survey of techniques," *International Journal of Computer Applications*, vol. 139, no. 11, pp. 5–15, Apr. 2016.
- [7] A. Zulqarnain, R. Ghazali, M. G. Ghouse, and M. F. Mushtaq, "Efficient processing of TF-IDF and Naive Bayes for sentiment analysis," *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 20, no. 1, pp. 512–518, Oct. 2020, doi:

- 10.11591/ijeecs.v20.i1.pp512-518.
- [8] G. Ranco, I. Bordino, G. Bormetti, G. Caldarelli, F. Lillo, and M. Treccani, "Coupling News Sentiment with Web Browsing Data Improves Prediction of Intra-Day Price Dynamics," *PLoS ONE*, vol. 11, no. 1, p. e0146576, Jan. 2016, doi: 10.1371/journal.pone.0146576.
 - [9] V. S. Pagolu, K. N. R. Challa, G. Panda, and B. Majhi, "Sentiment Analysis of Twitter Data for Predicting Stock Market Movements," in 2016 International Conference on Signal Processing, Communication, Power and Embedded System (SCOPES), Paralakhemundi, India, Oct. 2016, pp. 1345–1350, doi: 10.1109/SCOPES.2016.7955659.
 - [10] Z. Hu, W. Liu, J. Bian, X. Liu, and T.-Y. Liu, "Listening to chaotic whispers: A deep learning framework for news-oriented stock trend prediction," in Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining (WSDM '18), Marina del Rey, CA, USA, 2018, pp. 261–269, doi: 10.1145/3159652.3159690.
 - [11] I. Mozetič, M. Grčar, and J. Smailović, "Multilingual Twitter Sentiment Classification: The Role of Human Annotators," arXiv preprint arXiv:1602.07563, 2016. [Online]. Available: <https://arxiv.org/abs/1602.07563>
 - [12] D. A. Purnomo, "Research on data mining and machine learning classification using Naïve Bayes," Institut Teknologi dan Bisnis ASIA Malang, Google Scholar Profile. [Online]. Available: <https://scholar.google.com/citations?user=sfzTikEAAAJ&hl=en>
 - [13] Y. I. Kurniawan, "Perbandingan Algoritma Naive Bayes dan C4.5 dalam Klasifikasi Data Mining," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 5, no. 4, pp. 455–464, 2018, doi: 10.25126/jtiik.201854803.
 - [14] N. Firdausy, I. Yuadi, and I. Puspitasari, "Analisis Sentimen Evaluasi Reaksi E-Learning Menggunakan Algoritma Naïve Bayes, Support Vector Machine Dan Deep Learning," *Techno.Com*, vol. 22, no. 3, pp. 564–576, 2023, doi: 10.33633/tc.v22i3.8160.
 - [15] M. Luthfi, R. S. Perdana, and M. A. Fauzi, "Analisis Sentimen Cyberbullying pada Komentar Instagram dengan Metode Klasifikasi Support Vector Machine," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 2, no. 11, pp. 4704–4713, 2018.
 - [16] R. Wibowo, M. A. Soeleman, and A. Affandy, "Hybrid Top-K Feature Selection to Improve High-Dimensional Data Classification Using Naïve Bayes Algorithm," *Scientific Journal of Informatics*, vol. 10, no. 2, pp. 202–214, 2023, doi: 10.15294/sji.v10i2.42818.
 - [17] R. Kurniawan, M. A. Fauzi, and B. D. Setiawan, "Analisis Sentimen Masyarakat terhadap Kebijakan Publik Menggunakan Metode Naive Bayes dan Normalisasi Kata Tidak Baku," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 3, no. 3, pp. 2923–2930, 2019.
 - [18] Haixiang, L. Yijing, H. Shang, M. Xiaolong, L. Yu, and M. Bing, "Learning from class-imbalanced data: Review of methods and applications," *Expert Systems with Applications*, vol. 73, pp. 220–239, May 2017, doi: 10.1016/j.eswa.2016.12.035.
 - [19] R. A. Asmara, R. Septiana, and A. F. Hidayatullah, "Analisis Performa Algoritma Klasifikasi Sentimen Twitter terhadap Kebijakan Publik Menggunakan Metode ROC-AUC dan Confusion Matrix," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 6, pp. 1048–1055, 2021, doi: 10.29207/resti.v5i6.3587.
 - [20] D. Kurniasih and A. Setyawan, "Pengaruh Tahapan Preprocessing pada Analisis Sentimen Twitter Berbahasa Indonesia Menggunakan Naive Bayes," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 9, no. 4, pp. 789–798, 2022, doi: 10.25126/jtiik.2022945678.
 - [21] A. F. Hidayatullah, R. A. Asmara, and M. R. Ma'arif, "Evaluasi Kinerja Algoritma Klasifikasi pada Analisis Sentimen Media Sosial Menggunakan ROC-AUC dan Confusion Matrix," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 3, pp. 420–428, 2022, doi: 10.29207/resti.v6i3.3912.
 - [22] A. Rachman and D. Purwianti, "Analisis Sentimen pada Media Sosial Berbahasa Indonesia dengan Pendekatan Kontekstual dan Deteksi Sarkasme," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 8, no. 6, pp. 1187–1196, 2021, doi: 10.25126/jtiik.2021864732.
 - [23] M. S. Putri and N. A. Achsani, "Pengaruh Sentimen Investor terhadap Volatilitas Pasar Saham Indonesia dalam Perspektif Behavioral Finance," *Jurnal Ekonomi dan Keuangan*, vol. 6, no. 2, pp. 145–156, 2022.
 - [24] R. Fan, O. Talavera, and V. Tran, "Social media, political uncertainty, and stock markets," *Review of Quantitative Finance and Accounting*, vol. 55, no. 3, pp. 1137–1153, 2020, doi: 10.1007/s11156-020-00870-4.
 - [25] M. N. Ibnu Sina and E. B. Setiawan, "Stock Price Correlation Analysis with Twitter Sentiment Analysis Using The CNN-LSTM Method," *Sinkron: Jurnal dan Penelitian Teknik Informatika*,

- vol. 7, no. 4, pp. 2190–2202, 2023, doi: 10.33395/sinkron.v8i4.12855.
- [26] Y. Hong, T. Lim, and J. C. Stein, “Bad news travels slowly: Size, analyst coverage, and the profitability of momentum strategies,” *The Journal of Finance*, vol. 55, no. 1, pp. 265–295, 2000, doi: 10.1111/0022-1082.00206.