Analisis Sentimen Opini Publik terhadap Kebijakan Penghapusan Wisuda Pelajar di Jawa Barat Berbasis GRU dan SVM

Adeenda Putri Uswatun Chasanah
Program Studi Informatika PJJ
Fakultas Informatika
Telkom University
Bandung, Indonesia
adeendachaz@student.telkomuniversity.ac.id

Fitriyani
Program Studi Informatika PJJ
Fakultas Informatika
Telkom University
Bandung, Indonesia
fitriyani@telkomuniversity.ac.id

Media sosial kini berperan penting dalam membentuk opini publik karena memberikan ruang bagi masyarakat untuk mengutarakan pandangan secara cepat dan terbuka terhadap berbagai kebijakan publik. Salah satu isu yang sempat menarik perhatian publik yaitu kebijakan penghapusan wisuda pelajar di Jawa Barat, yang memicu berbagai respons hingga perdebatan di kalangan masyarakat, khususnya pada platform X dan YouTube. Kondisi seperti ini menunjukkan perlunya penerapan analisis sentimen sebagai pendekatan sistematis untuk mengklasifikan opini publik, sehingga pola respons masyarakat dapat dipahami secara lebih objektif. Urgensi topik ini muncul karena opini publik di media sosial tidak hanya merefleksikan respons masyarakat, tetapi juga berkontribusi dalam membentuk persepsi serta penilaian terhadap kebijakan yang diterapkan. Namun, karakteristik data pada media sosial yang cenderung tidak terstruktur disertai dengan ketidakseimbangan distribusi antar kelas sentimen menjadi tantangan tersendiri dalam proses analisis. Oleh karena itu, diperlukan pemilihan metode klasifikasi yang sesuai agar hasilnya dapat merepresentasikan opini publik dengan lebih akurat. Pada penelitian ini digunakan pendekatan analisis sentimen dengan menerapkan metode Gated Recurrent Unit (GRU) dan Support Vector Machine (SVM) dengan menggunakan 5.426 data komentar yang telah melalui tahapan preprocessing, pelabelan semi-manual menggunakan *lexicon-based*, serta proses ekstraksi fitur. Model SVM menerapkan representasi TF-IDF dengan dan tanpa teknik SMOTE, sedangkan model GRU menggunakan embedding layer dan penerapan *class weight* sebagai upaya untuk menangani ketidakseimbangan data. Proses evaluasi dilakukan menggunakan metrik *akurasi, precision, recall, F1-score,* serta *5-Fold cross-validation*. Berdasarkan hasil pengujian dengan beberapa skenario, model GRU dengan penerapan *class weight* dan jumlah epoch sebanyak 15 menunjukkan performa klasifikasi yang paling stabil. Distribusi sentimen didominasi oleh sentimen netral sebesar 64,16%, diikuti sentimen positif 34,20% dan negatif 1,64%. Temuan ini menunjukkan bahwa respons masyarakat terhadap kebijakan ini cenderung bersifat informatif dan normatif, dibandingkan dengan penolakan atau dukungan emosional yang berlebihan.

Kata kunci: analisis sentimen, GRU, SVM, media sosial, kebijakan

I. PENDAHULUAN

Media sosial saat ini telah berkembang menjadi sarana komunikasi global yang didukung oleh pesatnya kemajuan teknologi informasi di era ini [1]. Perkembangan tersebut memungkinkan informasi dari berbagai sudut pandang tersebar dengan cepat, sehingga secara perlahan membentuk kepercayaan serta opini publik. Di Indonesia, media sosial tidak hanya digunakan sebagai media interaksi, tetapi juga menjadi ruang bagi masyarakat untuk menyampaikan penilaian, baik dalam bentuk dukungan, kritik, maupun ketidakpuasan terhadap berbagai isu publik sesuai dengan perspektif masing-masing. Selain itu, dalam konteks politik, media sosial juga dimanfaatkan sebagai alat untuk menjangkau audiens yang lebih luas dan memengaruhi persepsi publik secara langsung [3].

Salah satu isu yang ramai diperbincangkan di media sosial adalah kebijakan penghapusan acara wisuda pelajar mulai dari tingkat TK hingga SMA di Jawa Barat yang digagas oleh Dedi Mulyadi (Gubernur Jawa Barat). Kebijakan tersebut bertujuan untuk meringankan beban psikologis dan ekonomi yang dirasakan para orang tua. Namun, dalam penerapannya, kebijakan ini menimbulkan beragam respons di masyarakat. Perdebatan dan berbagai komentar yang muncul di platform seperti X dan YouTube menunjukkan adanya perbedaan pandangan yang cukup jelas, sekaligus menunjukkan bagaimana interaksi di media sosial dapat memengaruhi persepsi serta tingkat kepercayaan publik terhadap kebijakan pemerintah.

Seiring meningkatnya intensitas diskusi publik di media sosial, diperlukan pendekatan analisis sentimen berbasis data teks yang mampu mengelompokkan opini masyarakat ke dalam kategori positif, netral, dan negatif secara sistematis. Sejumlah penelitian sebelumnya telah memanfaatkan berbagai pendekatan, mulai dari metode *lexicon-based*, teknik statistik, hingga machine learning. Namun, pendekatan-pendekatan tersebut masih memiliki keterbatasan terutama dalam memahami konteks bahasa serta menangani karakteristik teks media sosial yang cenderung informal, tidak terstruktur, dan memiliki distribusi kelas yang tidak seimbang.

Berbagai penelitian terdahulu menunjukkan bahwa model Support Vector Machine (SVM) yang dikombinasikan dengan representasi fitur TF-IDF memiliki performa yang baik dalam klasifikasi sentimen berbahasa Indonesia [1], serta unggul dalam efisiensi pelatihan dan penanganan ruang fitur berdimensi besar [19][20]. Akan tetapi, model ini cenderung sensitif terhadap ketidakseimbangan distribusi data, sehingga diperlukan penerapan teknik tambahan seperti Synthetic Minority Over-sampling Technique (SMOTE) untuk meningkatkan performanya [20]. Di sisi lain, pendekatan berbasis deep learning juga menunjukkan hasil yang signifikan. Model Gated Recurrent Unit (GRU) memiliki kemampuan untuk mempelajari urutan kata dan konteks secara lebih mendalam, sehingga dinilai efektif dalam menangani teks media sosial yang bersifat informal [2][22]. Meski demikian, model berbasis deep learning umumnya membutuhkan sumber daya komputasi yang lebih besar dibandingkan dengan machine learning konvensional [6].

Berdasarkan kajian terhadap penelitian sebelumnya, dapat dilihat bahwa model SVM dan GRU memiliki keunggulan yang saling melengkapi. Namun, penelitian yang secara khusus membandingkan performa kedua metode tersebut dalam konteks analisis sentimen terhadap isu kebijakan publik lokal di Indonesia masih relatif terbatas, terutama yang memanfaatkan data komentar media sosial (X dan YouTube). Oleh karena itu, penelitian ini difokuskan pada analisis sentimen opini publik terhadap kebijakan penghapusan wisuda pelajar di Jawa Barat dengan membandingkan performa metode Support Vector Machine (SVM) dan Gated Recurrent Unit (GRU). Data yang digunakan berasal dari komentar pengguna pada platform X dan YouTube untuk memberikan gambaran berbasis data mengenai respons masyarakat serta memperkaya kajian akademik terkait analisis sentimen kebijakan publik di Indonesia.

Penelitian ini difokuskan pada analisis sentimen opini publik terhadap kebijakan penghapusan wisuda pelajar di Jawa Barat yang berkembang di media sosial. Dalam konteks penelitian ini, analisis sentimen didefinisikan sebagai proses pengelompokan opini atau pendapat masyarakat yang diekspresikan dalam bentuk teks ke dalam kategori sentimen positif, netral, dan negatif. Opini publik yang dianalisis berasal dari komentar masyarakat sebagai respons terhadap kebijakan tersebut di platform X dan YouTube, yang merupakan ruang diskusi aktif dan terbuka bagi masyarakat untuk menyampaikan pandangan.

Permasalahan utama yang dikaji dalam penelitian ini adalah bagaimana opini publik terhadap kebijakan penghapusan wisuda pelajar dapat diklasifikasikan secara otomatis berdasarkan sentimennya, serta bagaimana performa metode klasifikasi yang digunakan dalam menangani teks media sosial yang cenderung bersifat informal. Secara konseptual, sistem analisis sentimen ini menerima masukan berupa teks komentar berbahasa Indonesia yang dikumpulkan melalui teknik crawling dengan menggunakan kata kunci yang berkaitan dengan kebijakan penghapusan wisuda pelajar. Keluaran sistem berupa label sentimen untuk setiap komentar, yaitu positif apabila komentar menunjukkan dukungan, netral apabila bersifat informatif atau tidak berpihak, dan negatif apabila berisi penolakan atau kritik terhadap kebijakan tersebut. Sebagai contoh, komentar yang menyatakan bahwa kebijakan tersebut dapat meringankan beban orang tua akan dikategorikan sebagai sentimen positif, sedangkan komentar yang menilai kebijakan tersebut merugikan siswa akan dikategorikan sebagai sentimen negatif.

Untuk menjaga fokus penelitian dan memastikan keterlaksanaannya dalam lingkup tugas akhir, penelitian ini menerapkan beberapa batasan. Data yang digunakan dibatasi pada komentar publik berbahasa Indonesia yang bersumber dari platform X dan YouTube dengan total 5.426 komentar setelah melalui proses pembersihan data. Pembatasan jumlah data ini dilakukan dengan mempertimbangkan keterbatasan waktu penelitian dan sumber daya komputasi yang tersedia. Selain itu, metode klasifikasi sentimen yang digunakan hanya mencakup Support Vector Machine (SVM) dan Gated Recurrent Unit (GRU) sebagai representasi pendekatan machine learning dan deep learning, sehingga metode lain tidak dibahas dalam penelitian ini.

Proses pemodelan dan evaluasi dilakukan menggunakan bahasa pemrograman Python dengan bantuan pustaka Scikit-learn serta TensorFlow/Keras. *5-fold cross-validation* diterapkan untuk evaluasi model dengan menggunakan metrik *akurasi, precision, recall, F1-score* dan *confusion matrix*. Penelitian ini juga dibatasi pada analisis sentimen yang bersifat statis, sehingga tidak mencakup analisis sentimen secara real-time maupun prediksi perubahan sentimen di masa mendatang. Dengan adanya batasan tersebut, penelitian ini diharapkan dapat menjadi dasar bagi pengembangan pada penelitian selanjutnya, khususnya dengan memperluas jumlah data, variasi metode, maupun perluasan cakupan analisis.

Penelitian ini bertujuan untuk memperoleh pemahaman yang lebih terstruktur mengenai sentimen publik terhadap kebijakan penghapusan wisuda pelajar di Jawa Barat berdasarkan komentar yang dikumpulkan dari media sosial X dan YouTube. Opini masyarakat diklasifikasikan ke dalam tiga kelas sentimen, yaitu positif, netral, dan negatif, sehingga distribusi serta kecenderungan respons publik terhadap kebijakan tersebut dapat dianalisis secara objektif.

Untuk mencapai tujuan tersebut, penelitian ini menerapkan dua pendekatan klasifikasi sentimen, yaitu Support Vector Machine (SVM) dan Gated Recurrent Unit (GRU), yang dirancang untuk menangani karakteristik teks opini berbahasa Indonesia yang cenderung bersifat informal dan tidak terstruktur. Performa kedua model kemudian dianalisis dan dibandingkan secara kuantitatif menggunakan metrik *akurasi, precision, recall, F1-score* dan *confusion matrix*, dengan penerapan teknik teknik *5-fold cross-validation* untuk menilai stabilitas dan keandalan masing-masing metode.

Hasil perbandingan tersebut diharapkan mampu menunjukkan metode klasifikasi yang paling efektif dalam menganalisis sentimen opini publik pada data media sosial. Temuan yang diperoleh tidak hanya memberikan gambaran berbasis data mengenai respons masyarakat terhadap kebijakan penghapusan wisuda pelajar, tetapi juga diharapkan dapat menjadi rujukan bagi penelitian selanjutnya serta mendukung pengembangan pengolahan opini publik secara otomatis dan lebih efisien

II. KAJIAN TEORI

Analisis sentimen telah banyak diteliti dengan memanfaatkan beragam algoritma klasifikasi, baik berbasis

machine learning konvensional maupun pendekatan *deep learning*. Sebuah studi sistematik dan bibliometrik yang dilakukan oleh Alfredo Daza et al. pada tahun 2024 di bidang *e-commerce* menunjukkan bahwa Support Vector Machine (SVM) dan Long Short-Term Memory (LSTM) merupakan metode yang paling dominan digunakan. Hal tersebut menandakan bahwa kedua pendekatannya masih memiliki relevansi yang kuat dalam pemrosesan teks opini [5].

Pada pendekatan *deep learning*, Shaik Vadla et al. menerapkan model BERT untuk melakukan ekstraksi aspek sentimen pada ulasan produk Amazon dan memperoleh nilai akurasi yang tinggi. Namun, penelitian tersebut juga menekankan bahwa BERT membutuhkan sumber daya komputasi yang besar, sehingga penggunaannya menjadi kurang efisien untuk dataset berskala kecil hingga menengah [6]. Kondisi ini menjadi pertimbangan penting dalam menentukan metode analisis sentimen ketika dihadapkan oleh keterbatasan sumber daya.

Penelitian lain oleh Aksh Patel et al. pada tahun 2023 yang membandingkan beberapa model *machine learning* dan *deep learning* pada data ulasan maskapai penerbangan. Hasil penelitian tersebut menunjukkan bahwa model berbasis Recurrent Neural Network (RNN), khususnya LSTM, memiliki keunggulan dalam memahami konteks temporal dalam kalimat [7]. Sejalan dengan temuan tersebut, Singgalen pada tahun 2024 menyebutkan bahwa Gated Recurrent Unit (GRU) mampu mencapai performa yang kompetitif dengan kebutuhan komputasi yang lebih efisien dibandingkan LSTM, terutama pada data teks yang bersifat informal [2].

Dalam konteks pemrosesan teks bahasa Indonesia, penelitian oleh Aryanti dan Mahendra pada tahun 2023 membuktikan bahwa SVM dengan representasi fitur TF-IDF, dengan menggunakan kernel RBF, mampu memberikan hasil yang optimal dalam mengklasifikan teks media sosial yang relatif pendek dan tidak baku [1]. Temuan ini juga diperkuat oleh penelitian Apriani dan Pratiwi pada tahun 2025 serta Suryanto dan Widyastuti di tahun yang sama, menyatakan bahwa SVM cenderung stabil dalam mengklasifikasikan opini publik, meskipun masih sensitif terhadap ketidakseimbangan distribusi kelas data [10][16].

Meskipun berbagai penelitian telah membahas keunggulan masing-masing metode, penelitian yang secara langsung membandingkan performa GRU dan SVM dalam konteks isu sosial dan kebijakan publik di Indonesia masih terbatas. Selain itu, pemanfaatan data yang bersumber lebih dari satu platform media sosial, khususnya X dan YouTube, juga belum banyak dilakukan. Oleh karena itu, penelitian ini berupaya mengisi celah tersebut dengan membandingkan performa GRU dan SVM dalam menganalisis sentimen opini publik terhadap kebijakan penghapusan wisuda pelajar di Jawa Barat.

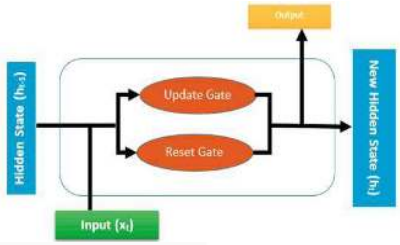
a. *Analisis Sentimen*

Analisis sentimen merupakan salah satu bagian dari Natural Language Processing (NLP) yang digunakan untuk mengidentifikasi dan mengklasifikasikan opini atau pandangan yang terdapat dalam teks ke dalam sentimen positif, netral, dan negatif [17]. Melalui proses ini, informasi dapat diekstraksi dari data teks yang tidak terstruktur sehingga kecenderungan pendapat masyarakat terhadap suatu isu dapat dipahami secara lebih sistematis [10].

Dalam konteks media sosial, analisis sentimen banyak dimanfaatkan untuk mengkaji respons masyarakat terhadap berbagai isu sosial, kebijakan publik, serta produk dan layanan [13]. Pendekatan yang umum digunakan dalam analisis sentimen meliputi metode *lexicon-based* serta pendekatan machine learning dan deep learning [14][15]. Pada penelitian ini, analisis sentimen diterapkan untuk mengolah komentar pengguna pada platform X dan YouTube yang berkaitan dengan kebijakan penghapusan wisuda pelajar.

b. *Gated Recurrent Unit (GRU)*

GRU merupakan salah satu arsitektur deep learning yang termasuk ke dalam Recurrent Neural Network (RNN) dan dirancang untuk memproses data yang bersifat sekuensial seperti teks [11]. Model ini dikembangkan sebagai bentuk penyederhanaan dari LSTM, namun tetap mempertahankan kemampuannya dalam mengatasi permasalahan vanishing gradient serta menangkap ketergantungan jangka panjang dalam data [12]. Arsitektur GRU terdiri dari dua gerbang utama, yaitu *update gate* dan *reset gate*, yang berfungsi mengatur aliran informasi selama proses pembelajaran.

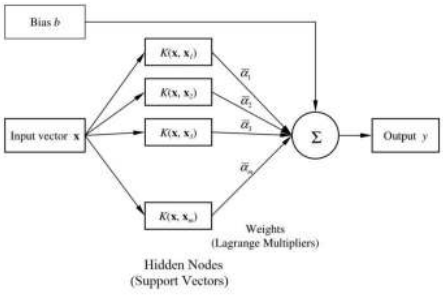


GAMBAR 1
Arsitektur GRU

Struktur GRU yang lebih sederhana membuat proses pelatihan menjadi lebih cepat dengan kebutuhan komputasi lebih rendah dibandingkan LSTM, namun tetap memberikan performa yang kompetitif dalam berbagai tugas klasifikasi [2]. Oleh karena itu, model GRU dinilai cocok untuk diterapkan pada analisis sentimen berbasis data media sosial yang umumnya didominasi oleh teks informal dan tidak terstruktur.

c. *Support Vector Machine (SVM)*

SVM merupakan salah satu algoritma *supervised learning* yang banyak diterapkan dalam tugas klasifikasi teks. Secara umum, SVM bekerja dengan menentukan sebuah *hyperplane* terbaik yang memisahkan data antar kelas dengan margin terbesar [1]. Metode ini memiliki keunggulan dalam menangani data berdimensi tinggi serta fleksibilitas melalui penggunaan berbagai jenis kernel, seperti linear, polynomial, dan Radial Basis Function (RBF) [10].



GAMBAR 2
Arsitektur SVM

Sejumlah penelitian menunjukkan bahwa SVM cukup efektif dalam mengklasifikan teks media sosial yang umumnya bersifat pendek dan tidak baku [10]. Namun, performanya dapat dipengaruhi oleh ketidakseimbangan distribusi kelas data [16]. Oleh karena itu, dalam penelitian ini SVM dikombinasikan dengan representasi fitur TF-IDF dan menggunakan kernel linear, yang dinilai sesuai dengan karakteristik data teks yang cenderung *sparse* dan memiliki dimensi tinggi.

d. *TF-IDF* (*Term Frequency–Inverse Document Frequency*)

TF-IDF merupakan salah satu teknik representasi fitur yang digunakan untuk mengonversi teks menjadi vektor numerik berdasarkan tingkat kepentingan kata baik dalam dokumen maupun keseluruhan korpus [15]. Komponen TF merepresentasikan seberapa sering sebuah kata muncul dalam sebuah dokumen, sedangkan IDF mengukur tingkat kelangkaan kata tersebut di seluruh dokumen. Dengan mengombinasikan kedua komponen tersebut, TF-IDF memberikan bobot yang lebih besar pada kata yang dianggap informatif dan relevan dalam merepresentasikan isi teks [24].

e. *Word Embedding*

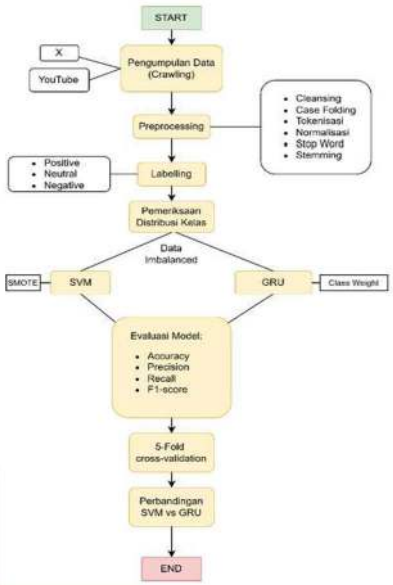
Word embedding merupakan teknik representasi kata dalam bentuk vektor berdimensi tetap, di mana kata-kata yang memiliki makna serupa direpresentasikan dengan vektor yang saling berdekatan. pendekatan ini memungkinkan model deep learning memahami hubungan semantik serta konteks antar kata secara lebih efektif dibandingkan metode konvensional seperti *one-hot encoding* [25]. Representasi embedding dapat diperoleh dari model yang telah dilatih sebelumnya (*pre-trained)* maupun dibentuk secara langsung melalui *embedding layer* selama proses pelatihan model.

f. *SMOTE (Synthetic Minority Oversampling Technique)*

SMOTE merupakan metode yang digunakan untuk menangani permasalahan ketidakseimbangan kelas dengan cara membuat sampel sintetis pada kelas minoritas berdasarkan pola data yang terdapat dalam data [17]. Berbeda dengan teknik oversampling sederhana, SMOTE dapat mempertahankan variasi data, sehingga mengurangi risiko terjadinya *overfitting* [19]. Dengan distribusi data yang menjadi lebih seimbang, kualitas performa klasifikasi model memungkinkan untuk meningkat secara keseluruhan [24].

III. METODE

Sistem yang dirancang dalam penelitian ini bertujuan untuk mengklasifikasikan sentimen opini publik terhadap kebijakan penghapusan wisuda pelajar di Jawa Barat berdasarkan komentar yang diperoleh media sosial. Sistem tersebut dirancang sebagai suatu alur pemrosesan teks yang mencakup tahap pengumpulan data, preprocessing text, pelabelan sentimen, hingga pemodelan dan evaluasi hasil klasifikasi.



GAMBAR 3
Flowchart Penelitian

a. *Pengumpulan dan Karakteristik Data*

Dataset dalam penelitian ini diperoleh melalui proses crawling komentar publik dari dua platform media sosial, yaitu X dan YouTube. Pengambilan data dari platform X dilakukan menggunakan *Tweet Harvest* dengan menggunakan lebih dari 20 kata kunci yang berkaitan dengan kebijakan penghapusan wisuda pelajar, nama tokoh yang terlibat, serta istilah-istilah yang umum digunakan masyarakat dalam membahas isu tersebut. Sementara itu, data dari YouTube dikumpulkan menggunakan *YouTube Data API v3* dengan cara mengekstraksi komentar dari video-video yang relevan dengan topik penelitian.

Pada tahap awal, data yang terkumpul berjumlah sekitar 8.000 komentar. Setelah melalui proses pembersihan dan seleksi bahasa, diperoleh sebanyak 5.426 komentar berbahasa Indonesia yang kemudian digunakan sebagai dataset utama dalam penelitian ini. Dataset ini merepresentasikan respons publik sejak fase awal hingga tahap lanjutan setelah kebijakan diumumkan, sehingga mampu menggambarkan dinamika opini masyarakat secara lebih menyeluruh.

b. *Preprocessing Text*

Tahap preprocessing dilakukan untuk mengubah data teks mentah menjadi format yang lebih seragam dan siap digunakan dalam proses pemodelan. Tahapan ini meliputi pembersihan teks dari karakter yang tidak relevan, URL, dan emoji, serta penerapan *case folding* untuk menyeragamkan penulisan huruf. Proses selanjutnya yaitu dilakukan *tokenisasi*, *normalisasi* kata tidak baku ke bentuk baku, *stopword removal*, dan penerapan *stemming* menggunakan stemmer Bahasa Indonesia. Melalui tahapan preprocessing ini, noise pada data akan berkurang sehingga kualitas representasi fitur teks menjadi lebih baik.

c. *Pelabelan Sentimen dan Distribusi Kelas*

Proses pelabelan sentimen dilakukan menggunakan pendekatan *lexicon-based* yang dikombinasikan dengan validasi semi-manual. Pendekatan *lexicon* digunakan untuk mempercepat proses pelabelan pada dataset yang berukuran besar, sementara validasi manual hanya difokuskan pada

komentar yang ambigu, sarkastik, atau menggunakan bahasa informal sehingga berpotensi mengalami kesalahan klasifikasi. Sentimen dalam penelitian ini dibagi ke dalam tiga kelas, yaitu positif, netral, dan negatif. Untuk mengetahui apakah distribusi data bersifat *balance* atau *imbalance*, maka dilakukan analisis distribusi kelas secara kuantitatif melalui perhitungan *imbalance ratio*. Nilai *imbalance ratio* dihitung dengan membandingkan jumlah data pada kelas mayoritas terhadap kelas minoritas.

$$IR = \frac{3379}{346} \approx 9.76$$

Hasil perhitungan menunjukkan bahwa dataset memiliki distribusi kelas yang tidak seimbang *(imbalanced),* dengan sentimen netral sebagai kelas mayoritas dengan jumlah 3.379 data teks dan sentimen negatif sebagai kelas minoritas dengan jumlah 346 data teks. Nilai imbalance ratio yang diperoleh memeperlihatkan adanya perbedaan proporsi yang signifikan antar kelas, sehingga diperlukan penanganan khusus pada tahap pemodelan agar model yang dibangun tidak bias terhadap kelas mayoritas.

d. *Ekstraksi Fitur dan Penanganan Ketidakseimbangan Data*

Pendekatan ekstraksi fitur dalam penelitian ini disesuaikan dengan karakteristik masing-masing model yang digunakan. Pada model SVM, representasi fitur dilakukan menggunakan metode TF-IDF untuk mengubah teks menjadi vektor numerik berdimensi tinggi. Untuk menangani masalah ketidakseimbangan data, pada salah satu skenario diterapkan teknik SMOTE guna menambahkan sampel sintetis pada kelas minoritas.

Sementara itu, pada model GRU, representasi teks dilakukan melalui *embedding layer*. Teks hasil tokenisasi terlebih dahulu dikonversi menjadi deretan indeks dan diproses dengan *padding* agar panjang input menjadi seragam. *Embedding layer* berperan dalam memetakan setiap kata ke dalam vektor numerik berdimensi tetap, sehingga hubungan dan konteks antar kata dapat dipelajari dengan lebih baik. Untuk mengatasi ketidakseimbangan kelas pada model GRU, diterapkan *class weight* agar model lebih responsif terhadap kelas minoritas selama proses pelatihan.

e. *Pelatihan dan Evaluasi Model*

Pelatihan model dilakukan menggunakan dua metode, yaitu Support Vector Machine (SVM) dan Gated Recurrent Unit (GRU). Pada SVM, pencarian parameter terbaik dilakukan menggunakan *GridSearchCV* baik pada skenario tanpa SMOTE maupun dengan SMOTE, sedangkan model GRU dilatih dengan beberapa konfigurasi untuk menganalisis pengaruh penerapan *class weight* terhadap performa model.

Evaluasi performa dilakukan menggunakan teknik *5-fold cross-validation* untuk memastikan kestabilan hasil dan meminimalkan overfitting. Performa modelnya diukur dengan metrik *akurasi, precision, recall, F1-score,* dan *confusion matrix,* dengan penekanan pada *F1-score* karena ketidakseimbangan kelas data.

f. *Perbandingan Model*

Hasil evaluasi digunakan untuk membandingkan performa model GRU dan SVM dalam mengklasifikasikan sentimen opini publik. Perbandingan ini bertujuan untuk mengidentifikasi metode yang paling efektif dan stabil performanya dalam mengolah teks media sosial yang informal, tidak terstruktur, serta memiliki distribusi kelas yang tidak seimbang, khususnya pada isu kebijakan publik di Indonesia.

IV. HASIL DAN PEMBAHASAN

a. *Hasil Pengujian*

Pengujian dilakukan dengan mmbandingkan dua pendekatan utama, yaitu model *deep learning* menggunakan GRU dan model *machine learning* menggunakan SVM. Untuk menghindari ketergantungan hasil pada satu konfigurasi tertentu, masing-masing model diuji melalui beberapa skenario dengan variasi parameter pelatihan. Seluruh eksperimen dilakukan menggunakan dataset yang sama dan dievaluasi dengan teknik *5-fold cross validation* menggunakan *metrik akurasi, precision, recall,* dan *F1-score* serta *confusion matrix*.

b. *Hasil Pengujian Model GRU*

Pengujian model GRU dilakukan dalam dua kondisi, yaitu dengan penerapan *class weight* dan tanpa penerapan *class weight*. Beberapa variasi parameter yang diuji meliputi jumlah epoch sebanyak 10, 15, dan 20 serta nilai dropout pada layer GRU dan dense, yang bertujuan untuk melihat pengaruh durasi pelatihan dan regularisasi terhadap performa serta stabilitas model.

Pada skenario GRU dengan *class weight*, pengujian difokuskan pada dua konfigurasi utama, yaitu pada epoch 10 dan 15 dengan nilai dropout yang relatif rendah. Hasil pengujian menunjukkan bahwa penerapan *class weight* mampu meningkatkan keseimbangan performa antar kelas dengan akurasi mencapai 0.8720, serta kemampuan yang lebih baik dalam mendeteksi kelas minoritas. Peningkatan jumlah epoch dari 10 menjadi 15 menghasilkan performa yang lebih stabil pada data validasi, dengan rata-rata akurasi *5-fold cross validation* sebesar 86,20% dan *confusion matrix* yang menunjukkan distribusi prediksi yang lebih merata antar kelas, sementara grafik loss dan accuracy mengindikasikan adanya overfitting ringan yang masih berada dalam batas wajar.

Sebaliknya, pada pengujian GRU tanpa *class weight*, dilakukan tiga skenario pengujian dengan variasi epoch 10, 15, dan 20. Hasil pengujian menunjukkan bahwa pada jumlah epoch rendah, model cenderung mengalami underfitting dan bias terhadap kelas mayoritas. Ketika jumlah epoch ditingkatkan, akurasi pada data latih meningkat secara signifikan, namun peningkatannya tidak diikuti oleh performa yang konsisten pada data validasi. Pola ini menunjukkan bahwa tanpa mekanisme penyeimbangan kelas, peningkatan kompleksitas pelatihan lebih cenderung menyebabkan overfitting dibandingkan peningkatan kemampuan generalisasi model.

c. *Hasil Pengujian Model SVM*

Sebagai model pembanding, SVM diuji dengan dua skenario, yaitu dengan penerapan SMOTE dan tanpa SMOTE, menggunakan representasi fitur TF-IDF serta

kernel linear. Proses optimasi parameter dilakukan menggunakan *GridSearchCV* dengan *5-fold cross validation*, sehingga pemilihan parameter dilakukan secara objektif dan konsisten pada kedua skenario pengujian.

Pada skenario SVM dengan SMOTE, nilai parameter regularisasi C diuji pada rentang yang lebih sempit yaitu [0.05, 0.1, 0.2, 0.3, 0.5] dengan menggunakan fungsi loss *squared hinge* untuk mengurangi risiko overfitting akibat penambahan data sintetis. Hasil pengujian menunjukkan bahwa pendekatan ini mampu menghasilkan performa yang lebih seimbang antar kelas, meskipun akurasi keseluruhan sedikit lebih rendah yaitu 0.8379. Sebaliknya, pada pengujian SVM tanpa SMOTE, rentang nilai C yang lebih luas yaitu [0.1, 0.5, 1, 2, 5] dengan 2 jenis fungsi loss *hinge* dan *squared hinge* yang memungkinkan model mencapai akurasi global yang lebih tinggi yaitu 0.8775, namun hasil evaluasinya menununjukkan adanya kecenderungan bias terhadap kelas mayoritas yang mengindikasikan keterbtasan SVM tanpa mekanisme penyeimbangan kelas dalam menangani ketidakseimbangan dataset.

d. Analisis Hasil Pengujian

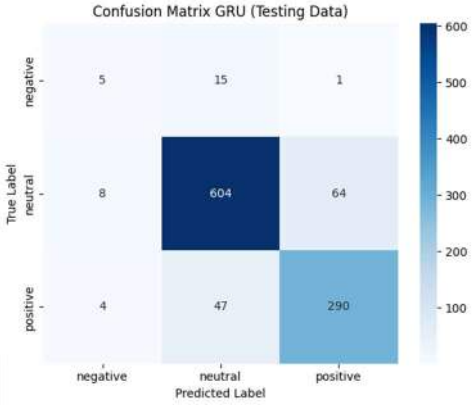
Hasil analisis pengujian menunjukkan bahwa strategi penanganan ketidakseimbangan kelas berpengaruh signifikan terhadap performa klasifikasi sentimen. Pada model GRU, penerapan *class weight* terbukti dapat meningkatkan kemampuan model dalam mengenali kelas minoritas serta menghasilkan distribusi prediksi yang lebih seimbang. Dibandingkan dengan GRU tanpa *class weight*, model ini juga menunjukkan performa yang lebih stabil dan baik pada berbagai jumlah epoch dan nilai dropout.

Pada model SVM, penerapan SMOTE berhasil meningkatkan keseimbangan performa antar kelas, namun berdampak pada penurunan akurasi keseluruhan yaitu menjadi 0.8379 dengan rata-rata akurasi *5-fold cross validation* sebesar 84.18%. Sebaliknya, SVM tanpa SMOTE mampu mencapai akurasi yang lebih tinggi yaitu 0.8775 dengan rata-rata akurasi *5-fold cross validation* sebesar 88.65%, tetapi cenderung bias terhadap kelas mayoritas. Hal ini menunjukkan adanya trade-off antara keseimbangan klasifikasi dan pencapaian akurasi global pada pendekatan SVM.

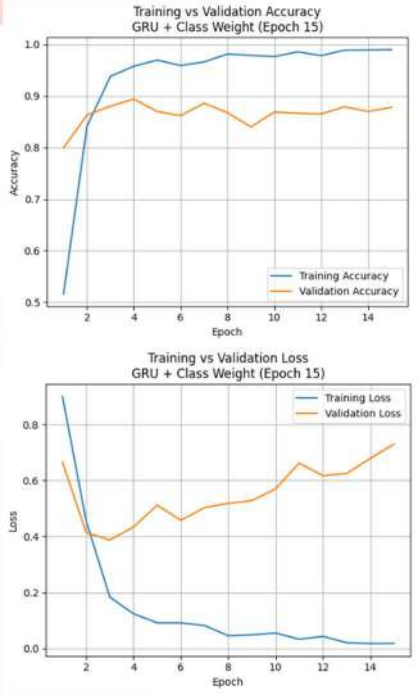
Secara keseluruhan, model GRU dengan penerapan *class weight* pada konfigurasi epoch 15 memberikan hasil paling optimal dengan mempertimbangkan aspek akurasi, keseimbangan performa antar kelas, dan kestabilan hasil pengujian. Oleh karena itu, konfigurasi tersebut dipilih sebagai model terbaik dalam penelitian ini. Sementara itu, model SVM dengan SMOTE tetap menunjukkan performa yang cukup stabil, sehingga layak dijadikan sebagai pembanding yang sesuai dalam penelitian ini.

TABEL 1
Hasil Pengujian Model GRU Class Weight dengan epoch 15

Akurasi	***Precision* (+)**	***Recall* (+)**	***F1 Score***	**Akurasi *Fold***
0.8720	*Negative*: 0.82 *Neutral*: 0.91 *Positive*: 0.82	*Negative*: 0.77 *Neutral*: 0.89 *Positive*: 0.85	*Negative*: 0.79 *Neutral*: 0.90 *Positive*: 0.83	*Fold* 1: 85.17% *Fold* 2: 87.10% *Fold* 3: 86.82% *Fold* 4: 84.61% *Fold* 5: 87.28% Rata-rata akurasi *fold*: 86.20%



GAMBAR 4
Confusion Matrix Model GRU Class Weight dengan epoch 15



GAMBAR 5
Grafik Loss dan Accuracy Model GRU Class Weight dengan epoch 15

Berdasarkan hasil klasifikasi menggunakan model yang paling optimal (GRU dan *class weight* dengan epoch 15), distribusi sentimen didominasi oleh sentimen netral sebesar 64,16%, diikuti sentimen positif sebesar 34,20% dan sentimen negatif sebesar 1,64%. Sentimen netral yang mendominasi mengindikasikan bahwa respons masyarakat terhadap kebijakan penghapusan wisuda pelajar cenderung bersifat informatif dan normatif.

V. KESIMPULAN

Berdasarkan hasil pengujian dan analisis terhadap komentar publik yang diperoleh dari media sosial X dan YouTube terkait kebijakan penghapusan wisuda pelajar oleh Gubernur Jawa Barat, dapat disimpulkan bahwa opini publik didominasi oleh sentimen netral. Hasil distribusi sentimen

menunjukkan bahwa sebesar 64,16% data termasuk kedalam sentimen netral, diikuti sentimen positif sebesar 34,20%, sementara sentimen negatif sebesar 1,64%. Temuan ini mengindikasikan bahwa respons publik terhadap kebijakan tersebut cenderung bersifat informatif dan tidak didominasi oleh reaksi emosional negatif.

Kemudian hasil pengujian model klasifikasi menunjukkan bahwa metode GRU memiliki tingkat kestabilan performa yang lebih baik dalam menangani data teks dengan distribusi kelas yang tidak seimbang dibandingkan dengan metode SVM. Penerapan class weight pada model GRU juga terbukti efektif dalam meningkatkan kemampuan model dalam mengenali kelas minoritas, yang ditunjukkan melalui peningkatan nilai recall pada sentimen negatif. Sementara itu, SVM dengan penerapan SMOTE tetap mampu menghasilkan performa yang kompetitif dan cukup stabil, sehingga menegaskan bahwa kedua model memiliki keunggulan masing-masing dalam analisis sentimen pada data yang bersifat tidak seimbang *(imbalanced)*.

Secara keseluruhan, hasil penelitian ini menunjukkan bahwa pemilihan metode klasifikasi dan strategi penanganan ketidakseimbangan data sangat berpengaruh terhadap kualitas hasil analisis sentimen. Model GRU dengan penerapan *class weight* dinilai sebagai model paling optimal pada penelitian ini karena mampu memberikan performa klasifikasi yang konsisten pada seluruh kelas sentimen.

Berdasarkan keterbatasan yang ditemukan selama proses penelitian, beberapa saran dapat diajukan untuk pengembangan penelitian selanjutnya. Penelitian yang akan datang disarankan untuk memperluas sumber dataset serta memperpanjang rentang waktu pengambilan data agar distribusi sentimen yang diperoleh menjadi lebih representatif. Selain itu, penggunaan model pemrosesan bahasa alami yang lebih kompleks, seperti BERT atau LSTM, dapat dipertimbangkan untuk meningkatkan pemahaman konteks bahasa pada data media sosial.

Penanganan ketidakseimbangan data juga dapat dikembangkan lebih lanjut dengan eksplorasi teknik penyeimbangan alternatif selain SMOTE atau dengan menambah data asli pada kelas minoritas. Terakhir, peningkatan stabilitas dan akurasi model dapat dilakukan melalui eksplorasi pengujian kombinasi parameter yang lebih beragam serta penerapan teknik augmentasi data yang sesuai dengan karakteristik teks berbahasa Indonesia.

REFERENSI

[1] Elektronik, J., Udayana, I. K., Ayu, P., Aryanti, N., Bagus, I., & Mahendra, M. (2023). Analisis Sentimen Opini Berbahasa Indonesia Pada Sosial Media Menggunakan TF-IDF dan Support Vector Machine. *JELIKU (Jurnal Elektronik Ilmu Komputer Udayana)*, *12*(1), 45–52. https://ojs.unud.ac.id/index.php/jlk/article/view/JLK.2023.v12.i01.p06

[2] Singgalen, Y. A. (2024). Sentiment Analysis and Trend Mapping of Hotel Reviews Using LSTM and GRU. *Journal of Information Systems and Informatics*, *6*(4), 2814–2836. https://doi.org/10.51519/JOURNALISI.V6I4.926

[3] Amelia, A., & Yusuf, R. (2025). ANALISIS SENTIMEN MASYARAKAT INDONESIA PADA PLATFROM X TERHADAP ISU FUFUFAFA MENGGUNAKAN BIDIRECTIONAL ENCODER REPRESENTATIONS FROM TRANSFORMERS. *Jurnal Informatika Teknologi Dan Sains (Jinteks)*, *7*(1), 72–80. https://doi.org/10.51401/JINTEKS.V7I1.5160

[4] Daza, A., González Rueda, N. D., Aguilar Sánchez, M. S., Robles Espíritu, W. F., & Chauca Quiñones, M. E. (2024). Sentiment Analysis on E- Commerce Product Reviews Using Machine Learning and Deep Learning Algorithms: A Bibliometric Analysis, Systematic Literature Review, Challenges and Future Works. *International Journal of Information Management Data Insights*, *4*(2), 100267. https://doi.org/10.1016/J.JJIMEI.2024.100267

[5] Shaik Vadla, M. K., Suresh, M. A., & Viswanathan, V. K. (2024). Enhancing Product Design through AI-Driven Sentiment Analysis of Amazon Reviews Using BERT. *Algorithms 2024, Vol. 17, Page 59*, *17*(2), 59. https://doi.org/10.3390/A17020059

[6] Patel, A., Oza, P., & Agrawal, S. (2022). Sentiment Analysis of Customer Feedback and Reviews for Airline Services using Language Representation Model. *Procedia Computer Science*, *218*, 2459–2467. https://doi.org/10.1016/J.PROCS.2023.01.221

[7] Apriani, E., & Pratiwi, N. (2025). Analisis Sentimen Game Show Clash of Champions Ruangguru dengan Algoritma KNN dan SVM. *Jurnal Pendidikan Dan Teknologi Indonesia*, *5*(1), 39–51. https://doi.org/10.52436/1.JPTI.556

[8] Niu, Z., Zhong, G., Yue, G., Wang, L. N., Yu, H., Ling, X., & Dong, J. (2023). Recurrent attention unit: A new gated recurrent unit for long-term memory of important parts in sequential data. *Neurocomputing*, *517*, 1–9. https://doi.org/10.1016/J.NEUCOM.2022.10.050

[9] Kawatu, C. I. (2024). *Penerapan Metode Gated Recurrent Unit Pada Analisis Sentimen Media Sosial*. https://repo.unsrat.ac.id/5167/7/Clinton%20Kawatu.pdf

[10] Ifantiska, D. (2024). ANALISIS SENTIMEN PADA DATA MEDIA SOSIAL MENGGUNAKAN METODE PEMBELAJARAN MESIN BERBASIS DEEP LEARNING. *Tugas Mahasiswa Program Studi Informatika*, *1*(1). https://coursework.uma.ac.id/index.php/informatika/article/view/681

[11] Tri Saputra, F., Nurhadryani, Y., Hartono Wijaya, S., Ilmu Komputer, D., Matematika dan Ilmu Pengetahuan Alam, F., & Pertanian Bogor, I. (2021). Analisis Sentimen Bahasa Indonesia pada Twitter Menggunakan Struktur Tree Berbasis Leksikon. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, *8*(1), 135–146. https://doi.org/10.25126/JTIIK.0814133

[12] Jurnal, A., Kartika Sari, A., Irsyad, A., Nur Aini, D., Elfriede Ginting, S., & Kunci, K. (2024). Analisis Sentimen Twitter Menggunakan Machine Learning untuk Identifikasi Konten Negatif. *Adopsi Teknologi Dan Sistem Informasi (ATASI)*, *3*(1), 64–73. https://doi.org/10.30872/ATASI.V3I1.1373

[13] Suryanto, S., & Andriyani, W. (2025). Sentiment Analysis of X Platform on Viral “Fufufafa” Account Issue in Indonesia Using SVM. *IJCCS (Indonesian*

Journal of Computing and Cybernetics Systems), *19*(1), 95–104. https://doi.org/10.22146/IJCCS.104158

[14] Saputra, J., Maryani, L., Rahmaddeni, Wulandari, D., & Eka, W. (2025). ANALISIS PERFORMA NAIVE BAYES DAN SVM TERHADAP SENTIMEN TEKS MEDIA SOSIAL DENGAN WORD2VEC DAN SMOTE. *Jurnal INSTEK (Informatika Sains Dan Teknologi)*, *10*(1), 143– 155. https://doi.org/10.24252/INSTEK.V10I1.54889

[15] Wahyudi, T., Azmi Verdikha, N., Muhammadiyah Kalimantan Timur, U., Ir Juanda No, J. H., Samarinda Ulu, K., Samarinda, K., & Timur, K. (2024). KLASIFIKASI SENTIMEN X-TWITTER PERIHAL PEMINDAHAN IBU KOTA INDONESIA MENGGUNAKAN EKSTRAKSI FITUR TF-IDF DAN METODE SUPPORT VECTOR MACHINE (SVM). *Jurnal Teknologi Informasi: Jurnal Keilmuan Dan Aplikasi Bidang Teknik Informatika*, *18*(2), 185–199. https://doi.org/10.47111/JTI.V18I2.15015

[16] Gusmansyah, R., Rahmaddeni, Hendrawan, H., & Rohid. (2025). PENINGKATAN KINERJA ANALISIS SENTIMEN PADA ULASAN APLIKASI IDENTITAS KEPENDUDUKAN DIGITAL (IKD) DI INDONESIA MENGGUNAKAN ALGORITMA SUPPORT VECTOR MACHINE (SVM) DAN SMOTE. *Jurnal INSTEK (Informatika Sains Dan Teknologi)*, *10*(1), 185–196. https://doi.org/10.24252/INSTEK.V10I1.55292

[17] Fahreza, S., & Setiawan, E. B. (2024). Sentiment Analysis on Social Media Using Word2Vec and Gated Recurrent Unit (GRU) with Genetic Algorithm Optimization. *International Journal on Information and Communication Technology (IJoICT)*, *10*(1), 62–77. https://doi.org/10.21108/IJOICT.V10I1.903

[18] Wang, X., & Nourmuhammadi, S. (2025). A novel framework for sentiment classification employing Bi-GRU optimized by enhanced human evolutionary optimization algorithm. *Scientific Reports 2025 15:1*, *15*(1), 17038-. https://doi.org/10.1038/s41598-025-01516-y