

Klasifikasi Emosi Terhadap Konflik Israel-Palestina Menggunakan Algoritma Gated Recurrent Unit

Eko Ikhwan Saputra¹, T.Sy. Eiva Fatdha², Agustin³, Junadhi⁴, M. Khairul Anam⁵

2010031802036@sar.ac.id¹, syarifahaiva@stmik-amik-riau.ac.id², agustin@sar.ac.id³, junadhi@sar.ac.id, khairula210@gmail.com⁴

^{1,2,3,4}Universitas Sains dan Teknologi Indonesia

⁵Universitas Samudra

Informasi Artikel

Diterima : 8 Jun 2024

Direvisi : 30 Jun 2024

Disetujui : 25 Jul 2024

Kata Kunci

Israel-Palestina, Gated Recurrent Unit, Global Vector, Klasifikasi Emosi, Deep Learning

Abstrak

Konflik Israel-Palestina kembali memanas setelah serangan 7 Oktober 2023 yang dilakukan oleh Hamas ke daerah Israel, ini memicu berbagai reaksi emosional di media sosial. Klasifikasi emosi penting untuk memahami sentimen publik terkait konflik ini. Penelitian ini menggunakan 9.917 tweet dari platform X (Twitter) untuk mengklasifikasikan emosi joy, sadness, anger, fear, disgust, dan surprise. Algoritma deep learning yang digunakan adalah Gated Recurrent Unit (GRU), yang dikembangkan dengan tiga pembagian data latih dan uji yang bervariasi: 70:30, 80:20, dan 90:10. Untuk representasi teks, digunakan word embedding GloVe. Mengingat dataset yang tidak seimbang, penelitian ini menerapkan teknik oversampling dengan Synthetic Minority Over-sampling Technique (SMOTE) untuk mengatasi ketidakseimbangan kelas emosi. Hasil penelitian menunjukkan bahwa model GRU dengan rasio pembagian data 90:10 tanpa menggunakan SMOTE memberikan akurasi tertinggi sebesar 75%, diikuti oleh model dengan rasio 70:30 dan 80:20 yang masing-masing memiliki akurasi sebesar 73%.

Keywords

Israel-Palestine, Gated Recurrent Unit, Global Vector, Emotion Classification, Deep Learning

Abstract

The Israel-Palestine conflict intensified following the October 7, 2023, attack by Hamas on Israel, triggering various emotional reactions on social media. Emotion classification is crucial for understanding public sentiment related to this conflict. This study utilizes 9,917 tweets from platform X (Twitter) to classify emotions such as joy, sadness, anger, fear, disgust, and surprise. The deep learning algorithm used is Gated Recurrent Unit (GRU), developed with three different training and testing data splits: 70:30, 80:20, and 90:10. For text representation, Global Vector (GloVe) word embedding is employed. Given the imbalanced dataset, this study applies the Synthetic Minority Over-sampling Technique (SMOTE) to address class imbalance. The research results indicate that the GRU model with a 90:10 data split without using SMOTE achieves the highest accuracy of 75%, followed by the models with 70:30 and 80:20 splits, which each have an accuracy of 73%.

A. Pendahuluan

Konflik Israel-Palestina kembali menjadi perbincangan dunia setelah Hamas melancarkan serangan ke daerah Israel pada 7 Oktober 2023. Awal mula timbulnya ketegangan antara Israel dan Palestina dapat ditelusuri kembali hingga munculnya gerakan Zionisme pada tahun 1895, yang diprakarsai oleh Theodor Herzl. Gerakan ini bertujuan untuk mendirikan sebuah negara yang secara khusus diperuntukkan bagi bangsa Yahudi [1]. Dalam konteks perjalanan waktu yang panjang, konflik antara Israel dan Palestina telah menjadi salah satu konflik berkelanjutan yang masih berlangsung hingga saat ini. Secara global, konflik ini juga diakui sebagai salah satu kontroversi paling signifikan di dunia [2]. Konflik ini pada dasarnya dipicu oleh persaingan atas kepemilikan tanah di wilayah Palestina [3].

Reaksi publik terhadap isu ini dapat dengan jelas diamati melalui berbagai platform media sosial. Salah satu platform media sosial yang sering digunakan oleh masyarakat adalah media sosial X [4]. *Tweet* yang diposting dapat mencerminkan ekspresi emosi atau perasaan individu yang mengunggahnya [5]. Emosi dapat didefinisikan sebagai tanggapan sadar seseorang terhadap suatu peristiwa atau situasi dalam jangka waktu tertentu (Wibawa & Pramarta, 2023). Emosi yang terdapat dalam suatu unggahan media sosial dapat diidentifikasi melalui proses analisis sentimen [5].

Konflik Israel-Palestina sangat sensitif sehingga publik mudah untuk ikut menyampaikan opininya di sosial media, contohnya seperti menyuarakan kemerdekaan untuk Palestina, menyerukan untuk memboikot produk dan layanan yang mendukung Israel, menangkal berita hoax atau bahkan menyebarkan berita hoax itu sendiri. Oleh karena itu diperlukan klasifikasi emosi terkait isu Israel-Palestina untuk dapat memahami emosi masyarakat terhadap isu ini sehingga dapat mencegah terjadinya salah persepsi.

Topik penelitian klasifikasi emosi pada teks sudah dilakukan sebelum-sebelumnya. Penelitian sebelumnya oleh Siddhanth[7] yang mengembangkan model klasifikasi emosi pada dataset yang disebut (dalam penelitian ini) *SmallEnglishEmotions*. Emosi diklasifikasikan ke dalam 5 label yaitu *happiness*, *sadness*, *anger*, *fear*, dan *other*. Total data pada dataset yaitu 6372 baris yang didapatkan melalui platform media sosial X dengan teknik *scrapping*, dataset ini dinamakan *SmallEnglishEmotions* karena teks yang dikumpulkan dengan rentang 20 kata hingga 70 kata, dengan rata-rata data yang terkumpul yaitu 50 kata. Selain itu, penelitian ini juga menggunakan *standard* dataset sebagai pembandingan performa pada model. Model-model pada penelitian ini dibangun dengan 4 algoritma, salah satunya yaitu *Bidirectional Encoder Representation from Transformers* (BERT). Pada penelitian ini model yang dibangun dengan algoritma BERT mendapatkan akurasi 46% pada *standard* dataset dan 67% pada *SmallEnglishEmotions* dataset. Penelitian lain yaitu oleh Iqra, dkk[8] yang mengembangkan model untuk klasifikasi emosi dengan eksperimen pada dua dataset, yaitu *SemEval-2018 Task 1C* dan *Ren-CECps*. Dataset *SemEval-2018 Task 1C* memiliki 11 label emosi, diantaranya adalah *anger*, *anticipation*, *disgust*, *fear*, *joy*, *love*, *optimism*, *pessimism*, *sadness*, *surprise* dan *trust*. Dataset ini tersedia dalam 3 bahasa yaitu Bahasa Arab, Bahasa Inggris dan Bahasa Spanyol, tetapi penelitian ini hanya menggunakan Bahasa Inggris saja. Sedangkan dataset *Ren-CECps* merupakan dataset berbahasa China. *Word embeddings* yang digunakan adalah

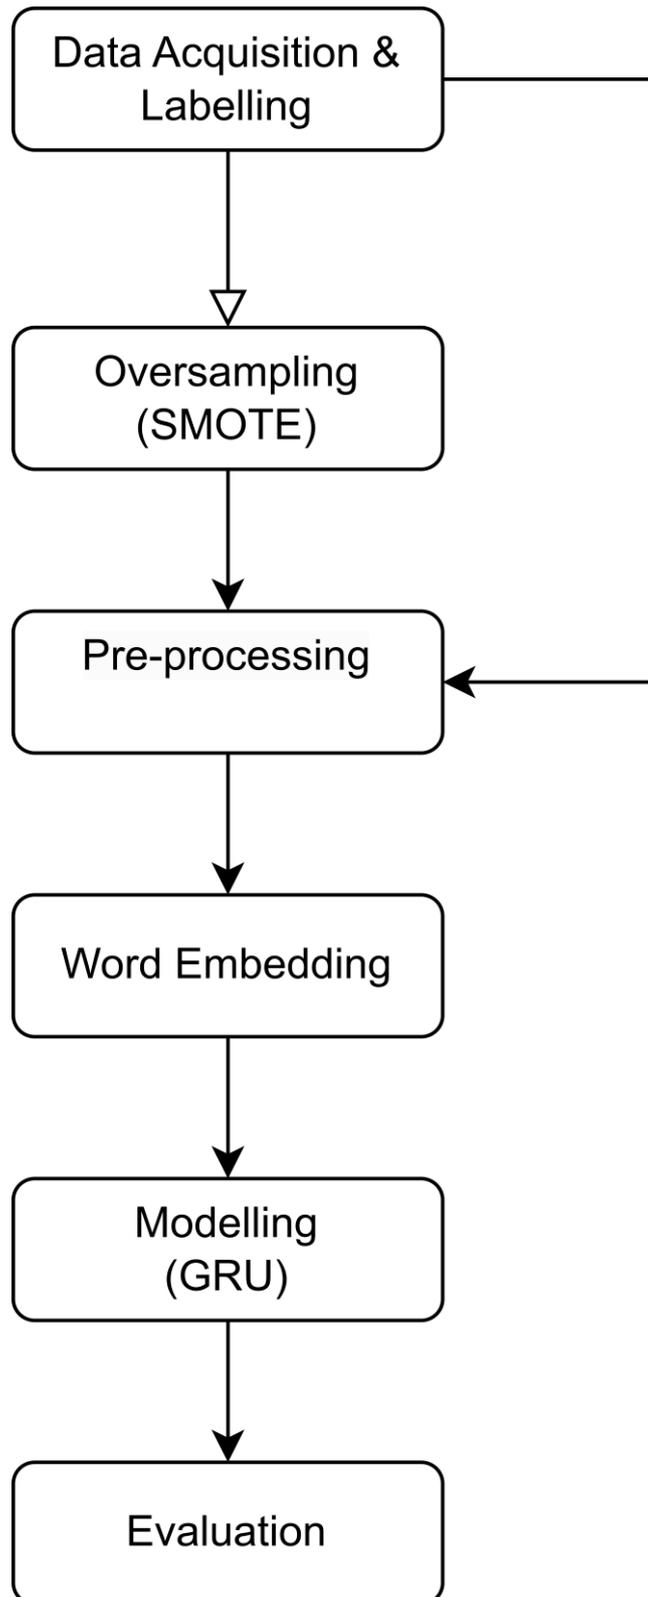
Global Vector (GloVe). Penelitian ini menggunakan beberapa algoritma untuk membangun beberapa model, performa (akurasi) terbaik pada dataset *SemEval-2018 Task 1C* yaitu model *RoBERTa Multi Attention* (RoBERTa-MA) dengan akurasi 62.4%. Penelitian klasifikasi emosi teks juga dilakukan oleh Batbaatar, dkk[9] dimana penelitian ini melakukan eksperimen berbagai algoritma untuk mengklasifikasikan emosi pada berbagai dataset emosi dan juga dikombinasikan dengan berbagai *word embeddings*. Salah satu algoritma yang digunakan adalah *Gated Recurrent Unit* (GRU), ketika dikombinasikan dengan *word embeddings Global Vector* (GloVe), model yang dibangun mendapatkan akurasi dibawah 60% dari 7 dataset yang ada.

Penelitian-penelitian yang telah dipaparkan pada paragraf sebelumnya masih belum mencapai performa model yang memuaskan, dimana akurasi pada model-model yang dikembangkan masih dibawah 70%. Penelitian-penelitian tersebut belum menerapkan *Synthetic Minority Oversampling Technique* (SMOTE), metode SMOTE diusulkan oleh Chawla pada tahun 2002, di mana kelas minoritas di-oversampling dengan menciptakan "data training sintesis"[10]. Dengan SMOTE, kelas minoritas diperluas dengan data buatan, ini dianggap lebih efektif daripada hanya mereplikasi data yang ada, sehingga jumlahnya setara dengan kelas mayoritas[11]. Dengan penerapan SMOTE, kelas dengan jumlah sampel lebih sedikit (kelas minoritas) ditingkatkan jumlahnya menggunakan duplikasi data sintesis yang dihasilkan, sehingga dapat mengatasi masalah distribusi data yang tidak seimbang[12].

Untuk membangun model klasifikasi emosi teks pada penelitian ini algoritma yang digunakan adalah *Gated Recurrent Unit* (GRU). Penelitian yang dilakukan oleh [13] menunjukkan bahwa algoritma GRU juga efektif digunakan untuk klasifikasi pada teks, dimana pada penelitian ini dilakukan analisis sentimen terhadap layanan rumah sakit selama pandemi *Covid-19*, data yang digunakan juga berupa *tweet* yang diunggah oleh masyarakat, penelitian ini menunjukkan bahwa GRU mendapatkan akurasi 86%. Penelitian lain yang dilakukan oleh Hanif, dkk [14] algoritma *Gated Recurrent Unit* (GRU) berhasil mencapai akurasi 97,16% dalam melakukan klasifikasi berita *clickbait*. Pada penelitian yang dilakukan oleh Batbaatar, dkk[9], algoritma GRU masih belum mendapatkan hasil yang optimal, tujuan dari penelitian ini adalah mengoptimalkan algoritma GRU dalam melakukan klasifikasi emosi pada teks dengan menggunakan *Synthetic Minority Oversampling Technique* (SMOTE).

B. Metode Penelitian

Penelitian ini menggunakan algoritma *Gated Recurrent Unit* untuk membuat model klasifikasi emosi, alur penelitian dapat dilihat pada Gambar 1.



Gambar 1. Alur Penelitian

1. Data Acquisition & Labelling

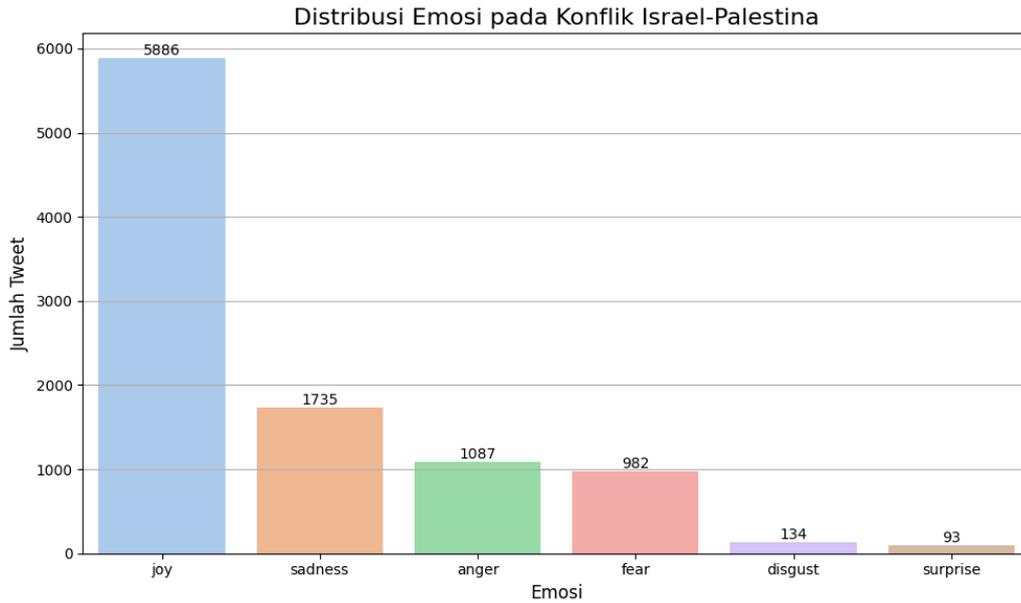
Dataset yang digunakan merupakan data *tweet* pengguna *X* di seluruh dunia yang terkait dengan kata kunci Israel-Palestine. Dataset ini dikumpulkan dari awal

konflik Israel-Palestina hingga data terakhir yang terkumpul pada dataset yaitu 15 Maret 2023. Dataset dikumpulkan dari berbagai bahasa didunia yang diterjemahkan kedalam Bahasa Inggris menggunakan *Google Sheets* dengan fungsi `=googletranslate()`. Kemudian data diberi label dengan jumlah label adalah 6, yaitu *joy, sadness, anger, fear, disgust* dan *surprise*. Hal ini dilakukan karena *Gated Recurrent Unit (GRU)* merupakan algoritma *supervised* yang membutuhkan label pada dataset selama proses *traininig*. Pelabelan menggunakan metode *lexicon based* dengan *library NRC Emotion Lexicon*. Hasil pelabelan dapat dilihat pada Tabel 1.

Tabel 1. Label pada data data

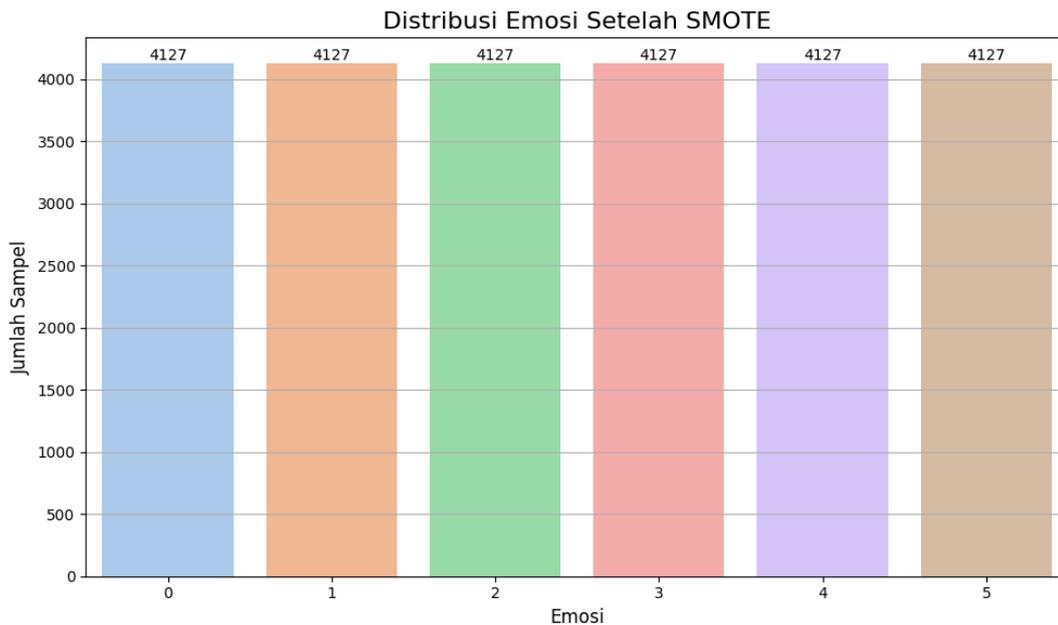
Teks	Label
RT Watch this video of today's terrorist attack in Jerusalfâ © n. This 13 -year -old terrorist is voyant from the brainwashing of incitement to hate and hate.	anger
Rt Putin estâmon bombing kyiv again. This must stop ... Ah, no ... it's Palestine being bombed by Israel last night. Keep up what they were doing ... nothing happens. https://t.co/0zws08zmg [re Roilopezrivass]	disgust
Urgent: Israelâfâ Colonos attack a Palestinian ambulance in the occupied city of Nablus. https://t.co/gazdgtt2jz	fear
Rt @jaimeernestoca1: #bastadepersucuciãgeâ ³ That is so that only Palestine will be free .. [Re Jaimeernestoca1]	joy
RT when bombarding people's houses in Jenin, Palestine; The Zionist Râfâ Gimem begins a new chapter of their cribs against the helpless people of Palestinaã ° âÿâ ð âµã ° âÿâ ð â, [RE ZAHRAZEINEDDIN]	sadness
@StrawberryNut4 @LaBupi150 @HoyPalestina Imaad, in 1948 was a plan to divide palestina and the palestinians did not accept it, they believe that the forces of arabs countries will entry to Israel as a trip, and their not! If you really care about palestin	surprise

Representasi dari hasil pelabelan menggunakan *library NRC Emotion Lexicon* dapat dilihat pada Gambar 2 yang menampilkan distribusi dari emosi pada konflik Israel-Palestina diserluruh dunia. Dataset terlihat tidak seimbang frekuensi antar kelasnya. Dimana sentiment *joy* menjadi yang teratas disusul dengan sentimen *sadness* dan seterusnya.



Gambar 2. Distribusi emosi

Dataset yang tidak seimbang akan buruk untuk model dalam mengklasifikasikan teks. Oleh sebab itu penelitian ini menggunakan teknik (algoritma) *Synthetic Minority Oversampling Technique* (SMOTE) untuk menyeimbangkan dataset.



Gambar 3 Hasil SMOTE

Gambar 3 menampilkan hasil operasi SMOTE dalam menyeimbangkan data, jika dibandingkan dengan Gambar 2, maka dilihat kelas minoritas telah seimbang dengan kelas mayoritas, sehingga ini akan membantu model dalam belajar mengklasifikasikan teks.

2. Pre-Processing

Di tahap ini dilakukan pengolahan pada data teks supaya siap untuk digunakan sebagai data latih pada model, karakter atau kata yang tidak penting dihilangkan pada proses ini. Langkah yang dilakukan dalam *pre-processing* ini yaitu *case folding*, di mana semua huruf dalam teks diubah menjadi huruf kecil [4], [15]. Selanjutnya adalah *stopwords removal*, di tahap ini kata-kata yang dianggap tidak penting yang termasuk dalam daftar *stopwords* dari teks hasil proses sebelumnya akan dihapus [4], [16]. Contoh bentuk kata yang akan dibuang pada tahap penghapusan *stopwords* mencakup kata-kata seperti "di", "oleh", "pada", "sebuah", "karena", dan sejenisnya [17]. *Stopwords list* yang digunakan berbahasa Inggris dari *nlk*. Tahap terakhir dalam proses ini adalah *stemming*, yang merupakan teknik untuk mereduksi kata-kata menjadi bentuk dasarnya berdasarkan aturan-aturan tertentu [4], [15]. Tujuan dari stemming adalah menghilangkan imbuhan pada setiap kata sehingga hanya tersisa bentuk dasar atau akar kata [17]. Hasil dari setiap proses pada tahap *pre-processing* dapat dilihat Tabel 2.

Tabel 2. *Pre-processing*

Proses	Hasil
Teks Original	And to make his threat believes they only need to give a cocaãfãna addict with cocaja with abstinence. More there of propaganda, the invasive entity in Palestine is aware that, the time, the arcãgegel raf raf After Case Folding: and to make his threat believes they only need to give a cocaãfãna addict with cocaja with abstinence. more there of propaganda, the invasive entity in palestine is aware that, the time, the arcãgegel raf raf
Case folding	and to make his that believes they only need to give a cocaãfãna addict with cocaja with abstinence mo the of propaganda the invasive entity in palestine is awa that the time the arcãgegel raf raf
Tokenization	['and', 'to', 'make', 'his', 'that', 'believes', 'they', 'only', 'need', 'to', 'give', 'a', 'cocaãfãna', 'addict', 'with', 'cocaja', 'with', 'abstinence', 'mo', 'the', 'of', 'propaganda', 'the', 'invasive', 'entity', 'in', 'palestine', 'is', 'awa', 'that', 'the', 'time', 'the', 'arcãgegel', 'raf', 'raf']
Stemming dan Stopwords removal	['make', 'believ', 'need', 'give', 'cocaãfãna', 'addict', 'cocaja', 'abstin', 'mo', 'propaganda', 'invas', 'entiti', 'palestin', 'awa', 'time', 'arcãgegel', 'raf', 'raf']
Hasil	make believ need give cocaãfãna addict cocaja abstin mo propaganda invas entiti palestin awa time arcãgegel raf raf

3. Word Embedding

Word embedding adalah sebuah fungsi parameter yang memetakan setiap kata ke dalam vektor berdimensi tinggi. Keunggulan dari *word embedding* adalah tidak memerlukan anotasi dan dapat langsung diturunkan dari korpus tak teranotasi [18]. Dengan menerapkan metode *word embedding*, informasi penting dari suatu dokumen dapat diperoleh berdasarkan makna kata-kata yang terkandung dalam dokumen tersebut [19]. *Word embedding* merupakan salah satu metode yang memberikan manfaat dengan harapan dapat mengidentifikasi pentingnya kata-kata dalam kalimat yang telah ditentukan sebelumnya [20]. Teknik *word embedding* yang dipakai pada penelitian ini adalah *Global Vector (GloVe)*. *Global Vector (GloVe)* merupakan representasi kata untuk menghasilkan *word embeddings* [21]. GloVe menggunakan metode *global matrix factorization*, matriks yang mewakili kemunculan atau ketiadaan kata-kata dalam suatu dokumen [18]. GloVe merupakan suatu metode *unsupervised learning* pada representasi kata yang mengungguli model lainnya di *word analogy*, *word similarity*, dan *named entity recognition* [21]. GloVe memiliki cara kerja dengan membuat matriks yang akan menghitung seberapa sering sebuah kata muncul [22]. GloVe akan menghasilkan *output list* yang berisikan *similarity words* yang selanjutnya akan dilanjutkan dengan proses ekspansi terhadap vektor [22].

4. Modelling

Tahap ini adalah proses membuat model dengan algoritma *Gated Recurrent Unit (GRU)*. Pada penelitian ini, model GRU dilatih dengan beberapa rasio pembagian data, yaitu 70% data latih dan 30% data uji, 80% data latih dan 20% data uji, serta 90% data latih dan 10% data uji. Ini dilakukan sebagai perbandingan dan untuk menemukan rasio data yang tepat untuk model. Lalu setiap rasio juga dilatih dengan data yang telah diseimbangkan oleh SMOTE untuk mengatasi ketidakseimbangan data. GRU adalah metode pengembangan dari *Recurrent Neural Network (RNN)* yang terbukti sangat efektif dalam mengatasi masalah sekuensial [23]. GRU merupakan bentuk penyederhanaan dari algoritma *Long Short-Term Memory (LSTM)*. Dalam GRU, input gate dan forget gate dari LSTM digabungkan menjadi sebuah update gate [14]. Update gate berperan dalam mengendalikan seberapa besar jumlah informasi baru yang akan disimpan dalam memori sel dalam konteks penggunaan GRU [13]. GRU memiliki keunggulan dalam hal jumlah bobot dan parameter yang lebih sedikit dibandingkan LSTM. Hal ini mengakibatkan kecepatan pelatihan model yang lebih cepat dibandingkan dengan penggunaan LSTM. Selain itu, implementasi GRU juga lebih sederhana dibandingkan dengan LSTM [24].

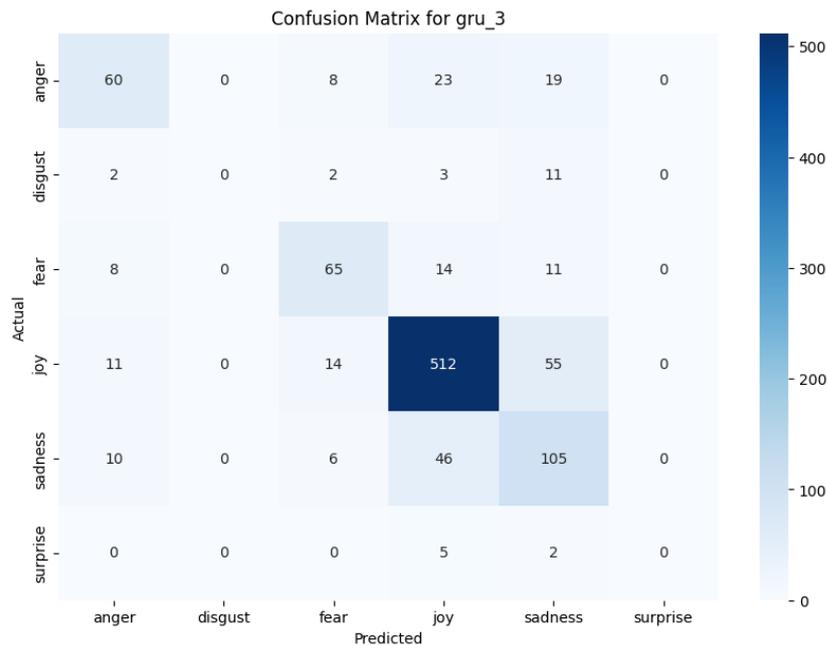
5. Evaluation

Evaluation (evaluasi) dilakukan untuk melihat dan mengukur performa dari model yang telah dilatih. Sebagai acuan untuk mengukur performa model di penelitian ini adalah *confusion matrix*. *Confusion matrix* adalah suatu tabel yang memuat informasi tentang sejauh mana sistem klasifikasi dapat mengklasifikasikan data uji dengan benar [25], [26]. Setelah mendapatkan hasil dari evaluasi setiap model, maka akan dapat dilakukan perbandingan dan menentukan model mana yang baik untuk klasifikasi emosi pada penelitian ini.

C. Hasil dan Pembahasan

Seperti yang telah dijabarkan pada sub-bab sebelumnya, bahwa data dilatih dengan beberapa rasio ditambah dengan SMOTE pada setiap rasio nya. Selain itu model yang dilatih diterapkan *Early Stopping*. Fungsi dari *early stopping* ini yaitu untuk menghentikan pelatihan pada model ketika parameter pada model tidak ada peningkatan, *early stopoping* yang diterapkan merupakan fitur dari *library TensorFlow*, penelitian ini *eraly stopping* digunakan untuk memantau *val accuracy* pada saat pelatihan model, dengan paraemter *patience* sebesar 3, sehingga ketika 3 *epoch* model tidak ada peningkatan pada *val accuracy*, maka pelatihan akan dihentikan. Selain itu, label yang tadinya berbentuk string akan dirubah dalam bentuk numerik. Perubahan atau konversi label ini menggunakan fitur *LabelEncoder* dari *library sickit-learn*.

Ketiga model dengan rasio berbeda yang di latih memiliki arsitektur yang sama, dimana memilik satu *embedding layer*, satu *model layer*, dan satu *dense (output) layer*. *Layer model* disusun dengan 128 *units*. *Activation* yang digunakan pada *dense layer* yaitu *activation softmax*. Kemudian arsitektur ini di *compile*, dimana pada saat *compile loss* yang digunakan adalah *sparse categorical crossentropy* dan *metrics* nya adalah *accuracy*. Hasil evaluasi dari model yang dibangun dapat dilihat pada gambar dibawah.



Gambar 4. Confusion matrix model GRU 90:10

```

Evaluating gru_3 for seknario_90...
31/31 [=====] - 0s 2ms/step
      precision    recall  f1-score   support

   anger         0.66      0.55      0.60        110
  disgust         0.00      0.00      0.00         18
    fear         0.68      0.66      0.67         98
     joy         0.85      0.86      0.86        592
  sadness         0.52      0.63      0.57        167
  surprise         0.00      0.00      0.00          7

 accuracy          0.75          992
 macro avg         0.45          992
 weighted avg         0.73          992

```

Gambar 5 Classification report model GRU 90:10

Model GRU dengan split data 90:10 memiliki akurasi tertinggi pada penelitian ini, yaitu 0.75. Kelas *joy* menunjukkan performa dengan nilai *precision* 0.85 dan *recall* 0.86, menghasilkan *f1-score* 0.86. Kelas *anger* menunjukkan performa dengan *precision* 0.66, *recall* 0.55, dan *f1-score* 0.60. Untuk kelas *fear* mendapatkan nilai *f1-score* 0.67. Lalu kelas *sadness* mendpaatkan nilai *f1-score* 0.57. Namun, kelas *disgust* dan *surprise* menunjukkan performa yang sangat rendah dengan *f1-score* 0.00, mengindikasikan bahwa meskipun akurasi model secara keseluruhan tinggi, model masih kesulitan mengenali emosi-emosi yang lebih jarang muncul. Performa dari seluruh model yang telah dikembangkan dapat dilihat pada Tabel 4.

Tabel 3 Performa model

Model	Precision	Recall	F1-Score	Accuracy
GRU 70:30	0.71	0.69	0.69	0.69
GRU 80:20	0.73	0.73	0.73	0.73
GRU 90:10	0.73	0.75	0.75	0.75
GRU 70:30 + SMOTE	0.63	0.57	0.59	0.57
GRU 80:20 + SMOTE	0.66	0.60	0.62	0.60
GRU 90:10 + SMOTE	0.65	0.60	0.62	0.60

Dari Tabel 4 dapat dilihat bahwa keenam model GRU yang dibangun mendapatkan akurasi yang belum memuaskan. Berdasarkan hasil dari keenam model GRU tersebut, terlihat bahwa rasio pembagian data mempengaruhi performa klasifikasi, hal ini terlihat pada kelas-kelas minoritas. Model GRU 90:10 tanpa SMOTE menjadi model terbaik secara keseluruhan. Model ini memiliki akurasi tertinggi (0.75), dan performa *precision*, *recall*, serta *f1-score* yang paling konsisten, terutama pada kelas *joy* yang memiliki support terbesar. Meskipun kelas *disgust* dan *surprise* memiliki performa rendah, ini adalah masalah yang terjadi di semua model dan tidak mengurangi kinerja umum model ini.

Temuan pada penelitian ini sejalan dengan penelitian sebelumnya oleh Thabtah, dkk yang menyatakan bahwa ketidakseimbangan pada data merupakan masalah utama pada model (algoritma) klasifikasi [27]. Kemudian diperkuat oleh hasil dari penelitian yang dilakukan oleh Kumar, dkk yang menyatakan bahwa dampak dari data yang tidak seimbang sangat buruk serta dapat mengurangi akurasi dan kinerja pada model [28].

D. Simpulan

Dari penelitian ini dapat disimpulkan bahwa arsitektur *Gated Recurrent Unit* (GRU) dapat melakukan klasifikasi emosi pada dataset Isrel-Palestina yang berasal dari *tweet* pada platform *X*. Dimana dataset ini berbahasa Inggris. Model GRU dengan rasio 90:10 tanpa *Synthetic Minority Oversampling Technique* (SMOTE) umumnya menunjukkan performa terbaik di antara keenam model. Penelitian ini memiliki keterbatasan, diantaranya yaitu dataset dikumpulkan dalam berbagai bahasa sebelum diterjemahkan kedalam Bahasa Inggris, setiap bahasa memiliki kebiasaan-kebiasaan yang berbeda dalam memposting *tweet*, setiap bahasa juga memiliki bahasa gaul nyat tersendiri yang tentunya hal-hal ini mempengaruhi performa dari klasifikasi model. Teknik SMOTE dalam penelitian ini digunakan untuk mengatasi ketidakseimbangan data, tetapi SMOTE juga dapat menyebabkan *overfitting* karena data sintesis yang dibuat mungkin tidak dapat merepresentasikan distribusi asli dari data sepenuhnya pada kelas minoritas. Hal-hal ini dapat mempengaruhi performa model pada seluruh metrik evaluasi sehingga memberikan gambaran yang tidak lengkap atau bias pada kelas mayoritas. Saran untuk penelitian selanjutnya yaitu menerapkan teknik penyeimbangan data lain untuk meningkatkan akurasi klasifikasi pada kelas minoritas dan mengumpulkan dataset hanya dalam satu bahasa sehingga tidak perlu diterjemahkan terlebih dahulu. Model GRU dengan rasio 90:10 tanpa SMOTE dapat dianggap sebagai model terbaik dari penelitian ini, namun masih diperlukan peningkatan lebih lanjut untuk menangani kelas-kelas minoritas dengan lebih efektif.

E. Referensi

- [1] A. B. Maharani, "Konflik Israel - Palestina," 2022, Doi: 10.13140/Rg.2.2.11250.38088.
- [2] A. Imtiaz, D. Khan, H. Lyu, Dan J. Luo, "Taking Sides: Public Opinion Over The Israel-Palestine Conflict In 2021," 2022, Doi: 10.48550/Arxiv.2201.05961.
- [3] B. M. Simanjorang *Dkk.*, "Pengaruh Konflik Palestina Dengan Israel Terhadap Gerakan Perlawanan Hamas Dan Dampaknya Bagi Indonesia," *Mediation: Journal Of Law*, Hlm. 24–30, Nov 2023, Doi: 10.51178/Mjol.V2i2.1591.
- [4] L. A. Andika, P. A. N. Azizah, Dan R. Respatiwan, "Analisis Sentimen Masyarakat Terhadap Hasil Quick Count Pemilihan Presiden Indonesia 2019 Pada Media Sosial Twitter Menggunakan Metode Naive Bayes Classifier," *Ijas*, Vol. 2, No. 1, Hlm. 34, Jul 2019, Doi: 10.13057/Ijas.V2i1.29998.
- [5] A. N. Sutranggono, "Klasifikasi Emosi Pada Cuitan Di Twitter Dengan Principal Component Analysis Dan Support Vector Machine," *Mu*, Vol. 10, No. 1, Hlm. 13–20, Apr 2022, Doi: 10.26740/Mathunesa.V10n1.P13-20.
- [6] P. W. A. Wibawa Dan C. Pramatha, "Systematic Literature Review: Machine Learning Methods In Emotion Classification In Textual Data," *Sisfokom*, Vol. 12, No. 3, Hlm. 425–433, Nov 2023, Doi: 10.32736/Sisfokom.V12i3.1787.
- [7] S. Bhat, "Emotion Classification In Short English Texts Using Deep Learning Techniques." Arxiv, 10 Maret 2024. Diakses: 31 Mei 2024. [Daring]. Tersedia Pada: [Http://Arxiv.Org/Abs/2402.16034](http://Arxiv.Org/Abs/2402.16034)
- [8] I. Ameer, N. Bölücü, M. H. F. Siddiqui, B. Can, G. Sidorov, Dan A. Gelbukh, "Multi-Label Emotion Classification In Texts Using Transfer Learning," *Expert*

- Systems With Applications*, Vol. 213, Hlm. 118534, Mar 2023, Doi: 10.1016/J.Eswa.2022.118534.
- [9] E. Batbaatar, M. Li, Dan K. H. Ryu, "Semantic-Emotion Neural Network For Emotion Recognition From Text," *Ieee Access*, Vol. 7, Hlm. 111866–111878, 2019, Doi: 10.1109/Access.2019.2934529.
- [10] A. A. Arifiyanti Dan E. D. Wahyuni, "Smote: Metode Penyeimbang Kelas Pada Klasifikasi Data Mining," *Universitas Pembangunan Nasional "Veteran" Jawa Timur*, Vol. 15, No. 1, Hlm. 34–39, Feb 2020, Doi: 10.33005/Scan.V15i1.1850.
- [11] Qorry Meidianingsih, D. E. Wardani, E. Salsabila, L. Nafisah, Dan A. N. Mutia, "Perbandingan Performa Metode Berbasis Support Vector Machine Untuk Penanganan Klasifikasi Multi Kelas Tidak Seimbang," *Statistika*, Vol. 23, No. 1, Hlm. 8–18, Jun 2023, Doi: 10.29313/Statistika.V23i1.1660.
- [12] E. Sutoyo Dan M. A. Fadlurrahman, "Penerapan Smote Untuk Mengatasi Imbalance Class Dalam Klasifikasi Television Advertisement Performance Rating Menggunakan Artificial Neural Network," *Jepin*, Vol. 6, No. 3, Hlm. 379, Des 2020, Doi: 10.26418/Jp.V6i3.42896.
- [13] A. Rolangon, A. Weku, Dan G. A. Sandag, "Perbandingan Algoritma Lstm Untuk Analisis Sentimen Pengguna Twitter Terhadap Layanan Rumah Sakit Saat Pandemi Covid-19," *Teika*, Vol. 13, No. 01, Hlm. 31–40, Mei 2023, Doi: 10.36342/Teika.V13i01.3063.
- [14] Anas Fikri Hanif, Theopilus Bayu Sasongko, Dan Arif Dwi Laksito, "Perbandingan Kinerja Lstm, Bi-Lstm, Dan Gru Pada Klasifikasi Judul Berita Clickbait," *Ijcs*, Vol. 12, No. 4, Agu 2023, Doi: 10.33022/Ijcs.V12i4.3281.
- [15] P. Arsi Dan R. Waluyo, "Analisis Sentimen Wacana Pemandangan Ibu Kota Indonesia Menggunakan Algoritma Support Vector Machine (Svm)," *Jtiik*, Vol. 8, No. 1, Hlm. 147, Feb 2021, Doi: 10.25126/Jtiik.0813944.
- [16] S. Khomsah Dan Agus Sasmito Aribowo, "Text-Preprocessing Model Youtube Comments In Indonesian," *Resti*, Vol. 4, No. 4, Hlm. 648–654, Agu 2020, Doi: 10.29207/Resti.V4i4.2035.
- [17] A. Z. Amrullah, A. S. Anas, Dan M. A. J. Hidayat, "Analisis Sentimen Movie Review Menggunakan Naive Bayes Classifier Dengan Seleksi Fitur Chi Square," 2020, Doi: 10.30812/Bite.V2i1.804.
- [18] A. Nurdin, B. A. S. Aji, A. Bustamin, Dan Z. Abidin, "Perbandingan Kinerja Word Embedding Word2vec, Glove, Dan Fasttext Pada Klasifikasi Teks," *Jurnal Tekno Kompak*, Vol. 14, No. 2, Art. No. 2, Agu 2020, Doi: 10.33365/Jtk.V14i2.732.
- [19] M. Fitri, "Perancangan Sistem Temu Balik Informasi Dengan Metode Pembobotan Kombinasi Tf-Idf Untuk Pencarian Dokumen Berbahasa Indonesia," *Justin (Jurnal Sistem Dan Teknologi Informasi)*, Vol. 1, No. 1, Hlm. 80–85, Mar 2013.
- [20] R. Ramadhan, Y. A. Sari, Dan P. P. Adikara, "Perbandingan Pembobotan Term Frequency-Inverse Document Frequency Dan Term Frequency-Relevance Frequency Terhadap Fitur N-Gram Pada Analisis Sentimen," *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, Vol. 5, No. 11, Art. No. 11, Okt 2021.
- [21] R. D. Indrapurasih, M. A. Bijaksana, Dan I. L. Sardi, "Implementasi Dan Analisis Kesamaan Semantik Antar Kata Bahasa Indonesia Menggunakan Metode

- Glove,” *Eproceedings Of Engineering*, Vol. 5, No. 3, Art. No. 3, Des 2018, Diakses: 17 Desember 2023. [Daring]. Tersedia Pada: <https://Openlibrarypublications.Telkomuniversity.Ac.Id/Index.Php/Engineering/Article/View/7304>
- [22] A. R. Fitriansyah Dan Y. Sibaroni, “Analisis Sentimen Terhadap Pembangunan Kereta Cepat Jakarta - Bandung Pada Media Sosial Twitter Menggunakan Metode Svm Dan Glove Word Embedding,” *Eproceedings Of Engineering*, Vol. 10, No. 2, Art. No. 2, Mei 2023, Diakses: 17 Desember 2023. [Daring]. Tersedia Pada: <https://Openlibrarypublications.Telkomuniversity.Ac.Id/Index.Php/Engineering/Article/View/20000>
- [23] F. A. Verilia, R. Firdaus, Dan H. D. Septama, “Pengembangan Pengenalan Aktivitas Manusia Secara Real Time Menggunakan Metode Convolutional Neural Network Dan Deep Gated Recurrent Unit,” *Ulil Albab : Jurnal Ilmiah Multidisiplin*, Vol. 2, No. 2, Hlm. 899–909, Jan 2023, Doi: 10.56799/Jim.V2i2.1351.
- [24] A. I. Caniago, W. Kaswidjanti, Dan J. Juwairiah, “Recurrent Neural Network With Gate Recurrent Unit For Stock Price Prediction,” *Telematika*, Vol. 18, No. 3, Hlm. 345, Okt 2021, Doi: 10.31315/Telematika.V18i3.6650.
- [25] B. Gunawan, H. S. Pratiwi, Dan E. E. Pratama, “Sistem Analisis Sentimen Pada Ulasan Produk Menggunakan Metode Naive Bayes,” *Jepin*, Vol. 4, No. 2, Hlm. 113, Des 2018, Doi: 10.26418/Jp.V4i2.27526.
- [26] D. Normawati Dan S. A. Prayogi, “Implementasi Naïve Bayes Classifier Dan Confusion Matrix Pada Analisis Sentimen Berbasis Teks Pada Twitter,” Vol. 5, 2021, Doi: 10.30645/J-Sakti.V5i2.369.
- [27] F. Thabtah, S. Hammoud, F. Kamalov, Dan A. Gonsalves, “Data Imbalance In Classification: Experimental Evaluation,” *Information Sciences*, Vol. 513, Hlm. 429–441, Mar 2020, Doi: 10.1016/J.Ins.2019.11.004.
- [28] P. Kumar, R. Bhatnagar, K. Gaur, Dan A. Bhatnagar, “Classification Of Imbalanced Data:Review Of Methods And Applications,” *Iop Conf. Ser.: Mater. Sci. Eng.*, Vol. 1099, No. 1, Hlm. 012077, Mar 2021, Doi: 10.1088/1757-899x/1099/1/012077.