

## Analisis Sentimen Masyarakat terhadap Tayangan Televisi Nasional menggunakan Metode *Deep Learning*

Ferhati Bouchra<sup>\*1</sup>, I Made Agus Dwi Suarjaya<sup>2</sup>, Ni Kadek Dwi Rusjyanthi<sup>3</sup>

Program Studi Teknologi Informasi, Fakultas Teknik, Universitas Udayana

Jl. Raya Kampus Udayana, 80361, Bali, Indonesia

Email: <sup>1</sup>ferhatibouchra@gmail.com, <sup>2</sup>agussuarjaya@it.unud.ac.id, <sup>3</sup>dwi.rusjyanthi@unud.ac.id

**Abstract.** *Analyzing Public Sentiment Toward National Television Broadcasts Using Deep Learning Methods.* Indonesia's television industry faces fierce competition, particularly in chasing ratings and ad revenue. This has ultimately led to declining broadcast quality on some national TV stations. This research aims to understand perceptions towards content quality by focusing on public opinion through sentiment analysis of social media (Twitter) using Bi-LSTM and Word2Vec methods. The research involved data collection, preprocessing, vectorization, data splitting, model training and testing, evaluation to find the best model, sentiment data classification, and finally, sentiment data analysis. Using a dataset of 515,492 sentiment points, the model achieved an accuracy of 96.4%, precision of 72.1%, recall of 72.0%, and f1-score of 72.8%. Analysis of Twitter user sentiment leans towards neutral and positive perceptions. The results of the sentiment analysis of Twitter users tend to be neutral and positive. The results of the public satisfaction trend show a change in the pattern of public satisfaction with the quality of television station content.

**Keywords:** national television, sentiment analysis, Twitter, deep learning, Bi-LSTM

**Abstrak.** Persaingan dalam industri televisi Indonesia mengalami persaingan yang sengit, terutama dalam mengejar rating dan jumlah iklan, yang akhirnya berdampak pada penurunan kualitas tayang dari beberapa stasiun televisi nasional. Kualitas tayangan televisi memiliki pengaruh besar terhadap masyarakat, terutama anak-anak yang memerlukan tayangan edukatif. Melalui analisis sentimen terhadap opini masyarakat, penelitian ini bertujuan untuk memahami persepsi terhadap kualitas konten yang disajikan dengan penggunaan data media sosial X (Twitter) menggunakan metode Bi-LSTM dan Word2Vec. Penelitian diawali dari pengumpulan data, preprocessing, vektorisasi Word2Vec, pembagian data, pelatihan dan pengujian model, evaluasi penentuan model terbaik, klasifikasi data sentimen, serta analisis data sentimen. Digunakan data sentimen sejumlah 515.492 yang menghasilkan akurasi sebesar 96,4%, precision sebesar 72,1%, recall sebesar 72,0%, dan f1-score sebesar 72,8%. Hasil analisis sentimen pengguna X(Twitter) cenderung netral dan positif. Hasil tren kepuasan masyarakat menunjukkan perubahan pola kepuasan masyarakat terhadap kualitas konten stasiun televisi.

**Kata Kunci:** televisi nasional, analisis sentimen, Twitter, deep learning, Bi-LSTM

### 1. Pendahuluan

Televisi adalah salah satu media yang paling disukai sebagai sumber hiburan dan informasi karena memiliki cara penyajian konten secara visual dan auditif. Televisi dapat memberikan tayangan film, sinetron, musik, *reality show*, dan lain sebagainya dengan melibatkan para selebritis yang digemari oleh masyarakat luas [1]. Televisi juga memungkinkan masyarakat untuk mengikuti berita terkini dan perkembangan global.

Saluran televisi nasional yang berjumlah dua puluh enam muncul di Indonesia pada tahun 2018. Saluran televisi nasional Indonesia pada tahun 2018 meliputi Global TV, SCTV, Metro TV, RCTI, iNews TV, Indosiar, RTV, MNCTV, Trans TV, ANTV, Trans 7, tvOne, SpaceToon, Kompas TV, O-Channel, dan NET. TV. Seluruh saluran televisi bersaing menggunakan program yang ditayangkan dengan tujuan menarik lebih banyak jumlah penonton dari saluran televisi lainnya yang dibuktikan dengan *rating* dan *share* televisi tersebut. Dampak yang didapat dari peningkatan angka *rating* dan *share* dari suatu saluran adalah kemungkinan meningkatnya jumlah iklan dan sponsor yang ditayangkan dalam program-programnya, sehingga pendapatan televisi

pun dapat meningkat [2]. Penurunan yang signifikan dalam kualitas tayangan televisi di Indonesia menjadi dampak dari peningkatan jumlah iklan yang ditayangkan dan semakin menguatkan dugaan bahwa cukup banyak saluran televisi lebih mengutamakan fokus pada perolehan *rating* dibandingkan dengan kualitas konten yang disajikan. Persaingan ketat untuk mempertahankan dan meningkatkan peringkat pemirsa diduga menjadi akibatnya, sehingga beberapa saluran televisi lebih memilih untuk condong pada strategi yang dapat menghasilkan angka *rating* yang tinggi dalam jangka pendek, bahkan jika itu dapat mengorbankan kualitas dan nilai dari konten yang diproduksi [3].

Penelitian terdahulu mengungkap bahwa tayangan yang tidak berkualitas memiliki pengaruh besar terhadap anak-anak yang belum mampu memilah tayangan edukatif. Maka dari itu, peran keluarga dalam memilah tontonan layak untuk anak-anak sangatlah penting [4]. Dampak dari fenomena ini semakin terlihat dari banyaknya opini yang disampaikan oleh masyarakat mengenai menurunnya kualitas tayang televisi Indonesia. Analisis sentimen merupakan alat yang dapat digunakan untuk mengetahui pendapat masyarakat dengan pengelompokan polaritas teks dan penentuan sentimen dalam suatu kalimat maupun dokumen. Pengelompokan dapat ditentukan sebagai sentimen positif, negatif, ataupun netral [5].

Penelitian ini memiliki tujuan untuk mengukur sentimen masyarakat mengenai kualitas delapan saluran televisi nasional di Indonesia. dengan menggunakan data dari media sosial Twitter. Dengan analisis sentimen, penelitian ini akan mengungkap kecenderungan sentimen masyarakat, apakah cenderung positif, negatif, atau netral terhadap permasalahan kualitas tayang televisi nasional pada masa ini.

## 2. Tinjauan Pustaka

### 2.1. Analisis Penelitian Terdahulu

Salah satu penelitian yang membandingkan LSTM dan Bi-LSTM untuk menganalisis sentimen pelanggan layanan Grab Indonesia menggunakan data yang diambil dari komentar pada aplikasi Grab dengan tiga kategori sentimen, yaitu positif, negatif, dan netral. Hasil menunjukkan bahwa Bi-LSTM memiliki kinerja yang lebih unggul dengan menghasilkan akurasi sebesar 91% dibandingkan dengan LSTM yang hanya menghasilkan akurasi 76% [6].

Penelitian serupa lainnya yang juga telah membandingkan metode LSTM dan Bi-LSTM pada identifikasi *cyberbullying* pada media sosial Twitter dengan menggunakan data *tweet* berbahasa Indonesia dengan dua kategori sentimen, yaitu positif dan negatif. Hasil penelitian menunjukkan bahwa kinerja Bi-LSTM lebih unggul pada seluruh hasil evaluasi yaitu *accuracy* sebesar 95,24%, *precision* sebesar 94,29%, *recall* sebesar 93,40%, dan *F1-Score* sebesar 93,84% [7].

Salah satu penelitian yang mengangkat topik klasifikasi sentimen terhadap publik figur di Indonesia menggunakan Bi-LSTM dengan data *tweet* berbahasa Indonesia. Penelitian membandingkan beberapa skenario jumlah *epoch* dengan hasil tertinggi pada 20 *epoch* yang menghasilkan akurasi 72,31% dan diikuti dengan *precision*, *recall*, dan *F1-score* secara urut sebesar 73,31%, 71,20%, dan 72,25%. Hasil analisis menunjukkan bahwa figur Maudy Ayunda memiliki persentase kelas positif tertinggi sebesar 81,90%, sementara Ahok memiliki persentase kelas negatif tertinggi sebesar 88,09%. Chef Juna memiliki persentase kelas netral tertinggi sebesar 94,60% [8].

Penelitian analisis sentimen lainnya mengenai sentimen publik dengan tiga kategori sentimen, positif, negatif, dan netral, yang membandingkan kinerja Bi-LSTM dan *Convolutional Neural Network* (CNN) membuktikan bahwa kinerja arsitektur Bi-LSTM menghasilkan akurasi 97,34%, *precision* sebesar 97,31%, *recall* sebesar 97,33%, dan *F1-score* sebesar 97,31% yang di mana lebih unggul dibandingkan arsitektur CNN yang mencapai kinerja terbaik dengan akurasi 94,40%, *precision* sebesar 94,39%, *recall* sebesar 94,40%, dan *F1-score* sebesar 94,39%. Arsitektur model Bi-LSTM yang digunakan meliputi beberapa lapisan, yaitu lapisan *Embedding*, lapisan Bi-LSTM, lapisan *GlobalMaxPooling1D*, lapisan *Dense*, dan lapisan *Dropout* [9].

Berdasarkan penelitian serupa yang telah dijelaskan dapat disimpulkan bahwa Bi-LSTM dapat digunakan untuk mengklasifikasikan atau mendeteksi sentimen pada data teks dengan

cukup baik. Terdapat beberapa faktor yang dapat mempengaruhi hasil performa model, seperti arsitektur model yang digunakan, pembagian kategori sentimen serta varian *hyperparameter* yang digunakan.

## 2.2. Analisis Sentimen

Penelitian analisis sentimen merupakan salah satu penelitian yang cukup populer dalam bidang *Natural Language Processing* (NLP). Analisis sentimen adalah sebuah proses komputasi yang berperan penting dalam mengklasifikasikan data tekstual sesuai dengan sentimen yang terkandung di dalamnya [10]. Data tekstual yang menjadi objek analisis dapat berupa pendapat atau emosi terhadap suatu entitas.

## 2.3. Long Short-Term Memory

LSTM (*Long Short Term Memory*) merupakan salah satu varian khusus *deep learning* yang termasuk dalam metode *Recurrent Neural Network* (RNN). LSTM dirancang untuk mengolah model data yang memiliki urutan panjang. Model LSTM memiliki konsep sel memori dalam penyimpanan informasi jangka panjang, yang merupakan solusi dari keterbatasan RNN yang kesulitan dalam mempelajari ketergantungan jangka panjang yang melibatkan banyak langkah [11].

Setiap satu unit LSTM memiliki komponen yang disebut *memory cell* yang menyimpan informasi dalam jangka panjang. Proses membaca dan memodifikasi *memory cell* dikendalikan oleh gerbang *sigmoid* yang mempengaruhi *input gate*, *output gate*, dan *forget gate*. *Input gate* memutuskan penambahan informasi yang akan diperbarui, *forget gate* memutuskan informasi yang akan dibuang dan disimpan, sedangkan *output gate* memutuskan informasi keluaran yang akan digunakan untuk proses selanjutnya [12].

## 2.4. Bidirectional Long Short-Term Memory

Bi-LSTM (*Bidirectional Long Short Term Memory*) merupakan suatu pengembangan terhadap metode LSTM dalam dunia *deep learning* dengan mengkombinasikan dua lapisan LSTM [13]. Salah satu tujuannya adalah untuk mengatasi kelemahan yang dimiliki oleh LSTM, di mana LSTM hanya dapat memproses data dalam satu arah. Pendekatan *bidirectional* mengatasi kelemahan tersebut dengan memproses data secara dua arah.

Dua lapisan LSTM yang bekerja memproses data secara dua kali, LSTM pertama digunakan untuk memproses input data ke arah depan, sedangkan LSTM kedua digunakan untuk memproses input data ke arah belakang [14] dan dimanfaatkan untuk memahami konteks dan hubungan antara kata-kata dalam teks dengan lebih baik. Arah pemrosesan data yang menjadi dua arah, memungkinkan Bi-LSTM untuk lebih efektif menangkap informasi yang terkandung dalam urutan kata-kata dalam teks.

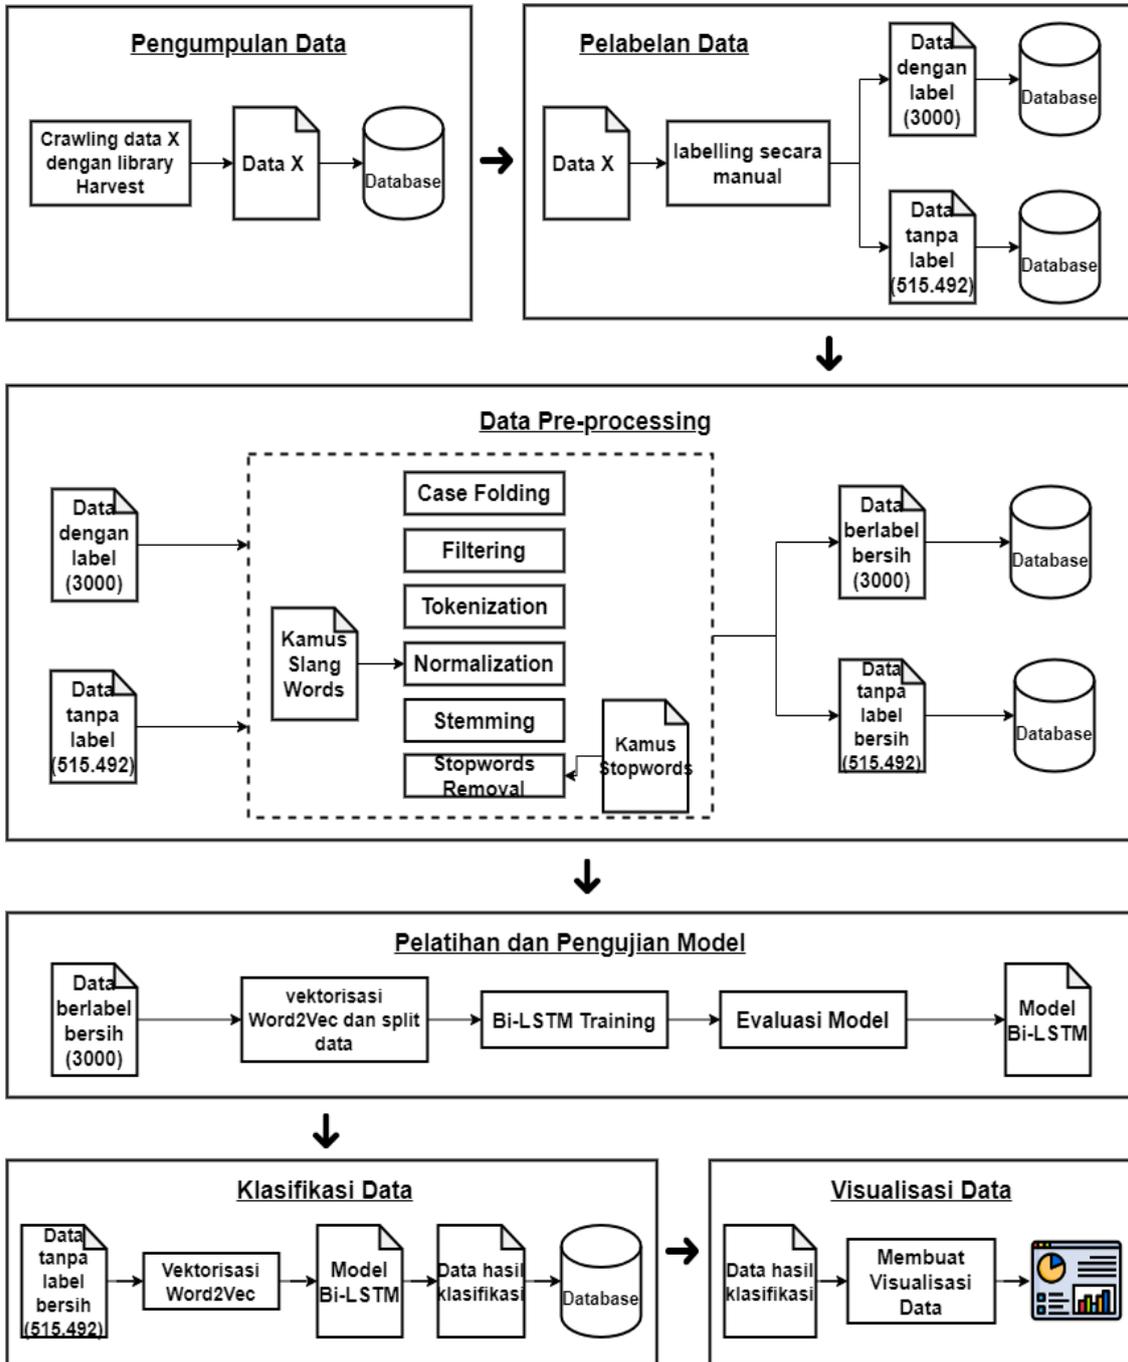
## 2.5. Word2Vec

Word2Vec merupakan sebuah vektor *representation* yang dapat digunakan untuk merepresentasikan setiap kata dalam bentuk vektor dengan ukuran N dimensi tertentu [10]. Konsep Word2Vec melibatkan rumus matematika dan metode ini dapat dimanfaatkan dalam aplikasi NLP untuk memahami makna dan hubungan antar kata. Model arsitektur ini menggunakan jaringan saraf (*neural network*) untuk menghitungnya, dengan input merupakan kata-kata dalam bentuk teks, dan outputnya merupakan vektor dalam ruang dimensi yang menangkap makna semantik dari sebuah kata. Hasilnya adalah vektor kata yang merepresentasikan makna kata-kata tersebut [15].

## 3. Metodologi Penelitian

Gambaran umum digunakan untuk memberikan pandangan terhadap tahapan atau langkah-langkah yang dilakukan pada penelitian. Proses yang digunakan untuk penelitian ini dibagi menjadi beberapa bagian, yaitu pengumpulan data, *data preprocessing*, pelatihan model,

klasifikasi data, dan visualisasi data. Gambaran dari gambaran umum pada penelitian ini dapat dilihat pada Gambar 1.



Gambar 1. Gambaran Umum Penelitian

### 3.1. Pengumpulan dan Pelabelan Data

Data *post* yang dikumpulkan merupakan hasil dari *crawling* menggunakan *library* Harvest<sup>1</sup> dengan kata kunci yang relevan, yaitu delapan saluran TV nasional Indonesia yang telah ditentukan. Data yang terkumpul sebanyak 518.492 yang tersimpan dalam format CSV.

<sup>1</sup> <https://github.com/helmisatria/tweet-harvest>

Data yang telah terkumpul kemudian diseleksi untuk diberikan label secara manual berdasarkan kriteria sentimen positif, negatif, dan netral. Proses pelabelan memperhatikan konteks, makna, dan kata emosi yang merujuk pada sentimen tertentu. Kalimat yang mengandung kata emosi dengan makna positif diberi label positif, sedangkan yang mengandung kata emosi dengan makna negatif diberi label negatif. Sentimen netral memiliki dua kriteria: kalimat yang tidak memiliki kata emosi dan tidak memberikan makna yang merujuk pada sentimen negatif atau positif serta kalimat yang mengandung sentimen positif dan negatif. Setiap kategori sentimen mendapatkan 1.000 data, sehingga total data berlabel berjumlah 3.000. Sisa data berjumlah 515.492 tidak diberi label karena akan digunakan untuk proses klasifikasi data. Contoh hasil data yang terkumpul dan telah diberikan label secara manual dapat dilihat pada Tabel 1.

**Tabel 1. Contoh Data dengan Label**

Teks	Label
Kangen WIB ðŸ˜- emang Televisi A ini acaranya berkualitas bgt hiks.	Positif
kalo libur nonton drakor di laptop sepupu terus sering nonton variety shownya exo ðŸ˜»ðŸ˜» seru banget jaman 2015-2018 terus dulu pas twitter masih kotak suka ikut ngrim tweet selamat pagi indonesia biar di notis masuk tv di Televisi A aHAHAHAHAHA	Positif
Betull aku suka nonton di Televisi A	Positif
@cheolxn @convomf Dulu kirain Televisi A bakal jadi stasiun yang idealis dan konsisten sama kualitas acara tayangannya eh taunya tetep ngikutin jalur TV swasta lain jadi jelek.	Negatif
@HabisNontonFilm acara Televisi B jelek2 drakor jadul lah acara yg ngambil potongan video tiktok lah acara makanan ala2 lah nah sekarang jiplak acara trans group wkwk tv	Negatif

### 3.2. Preprocessing

Tahap selanjutnya adalah *preprocessing* dengan enam teknik, yaitu *case folding*, *filtering*, *tokenization*, *normalization*, *stopwords removal*, dan *stemming*. Contoh hasil *preprocessing* dapat dilihat pada Tabel 2.

**Tabel 2. Contoh Hasil Preprocessing**

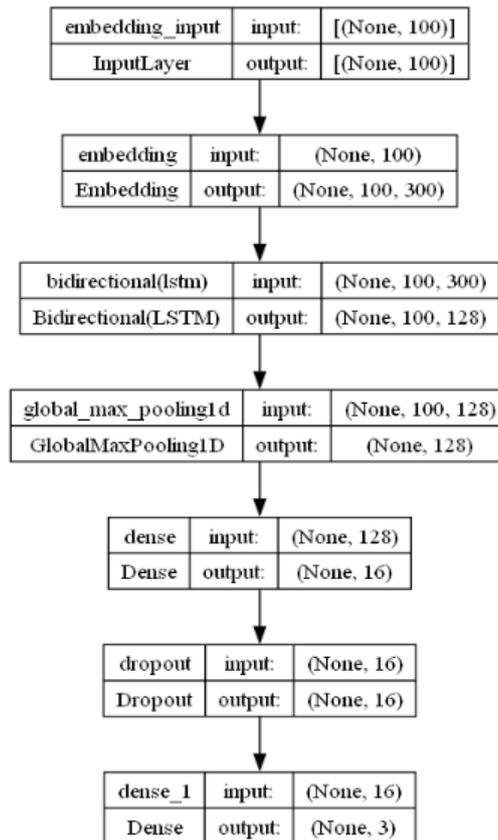
Text	Tahap Preprocessing	Hasil
@TelevisiB nonton acara malam ini di program Suara Cahaya Nusantara sangat puas... acara yg spektakuler... canggih... hebat... menghibur... Bravo... saya mo nonton ulang lg...	<i>Case Folding</i>	@televisib nonton acara malam ini di program suara cahaya nusantara sangat puas... acara yg spektakuler... canggih... hebat... menghibur... bravo... saya mo nonton ulang lg...
	<i>Filtering</i>	nonton acara malam ini di program suara cahaya nusantara sangat puas acara yg spektakuler canggih hebat menghibur bravo saya mo nonton ulang lg
	<i>Tokenization</i>	['nonton', 'acara', 'malam', 'ini', 'di', 'program', 'suara', 'cahaya', 'nusantara', 'sangat', 'puas', 'acara', 'yg', 'spektakuler', 'canggih', 'hebat', 'menghibur', 'bravo', 'saya', 'mo', 'nonton', 'ulang', 'lg']
	<i>Normalization</i>	['nonton', 'acara', 'malam', 'ini', 'di', 'program', 'suara', 'cahaya', 'nusantara', 'sangat', 'puas', 'acara', 'yang', 'spektakuler', 'canggih', 'hebat', 'menghibur', 'bravo', 'saya', 'mau', 'nonton', 'ulang', 'lagi']
	<i>Stemming</i>	['nonton', 'acara', 'malam', 'ini', 'di', 'program', 'suara', 'cahaya', 'nusantara', 'sangat', 'puas', 'acara', 'yang', 'spektakuler', 'canggih', 'hebat', 'hibur', 'bravo', 'saya', 'mau', 'nonton', 'ulang', 'lagi']
	<i>Stopwords Removal</i>	nonton acara malam program suara cahaya nusantara puas acara spektakuler canggih hebat hibur bravo nonton ulang

### 3.3. Pelatihan dan Pengujian Model

Tahap selanjutnya adalah pelatihan model yang dilakukan menggunakan arsitektur Bi-LSTM, model dirancang secara sekuensial dengan total enam lapisan. Penggunaan lapisan dimulai dengan lapisan *Embedding* yang mengubah kata-kata input menjadi vektor dengan dimensi output 300 dari model Word2Vec. Lapisan kedua adalah Bi-LSTM dengan 64 unit yang memproses data secara dua arah untuk memahami konteks temporal atau urutan pada data. Lapisan ketiga, *GlobalMaxPooling1D* mengurangi dimensi dengan mencari nilai maksimum dari setiap dimensi, sehingga memberikan representasi global yang lebih sederhana. Lapisan keempat

adalah lapisan *Dense* dengan 16 neuron dan fungsi aktivasi ReLU untuk mempelajari representasi kompleks, sementara lapisan keenam juga merupakan lapisan *dense* dengan 3 neuron dan fungsi aktivasi *Softmax* untuk menghasilkan probabilitas pada setiap kelas. Lapisan kelima adalah *Dropout* sebesar 0,2 untuk upaya pencegahan *overfitting*.

Selain lapisan model yang telah dibuat, terdapat pengoptimalan nilai-nilai *hyperparameter* untuk menemukan kombinasi yang dapat memberikan kinerja terbaik. Pemilihan nilai *hyperparameter* didasarkan dengan pertimbangan pengalaman dan karakteristik dari eksperimen yang telah dihadapi sebelumnya. *Optimizer* menjadi salah satu *hyperparameter* yang berperan dalam mengoptimalkan *loss function* dengan memperbaiki parameter model. Algoritma optimasi yang digunakan adalah Adam (*Adaptive Moment Estimation*) karena umum digunakan dan dikenal bekerja dengan baik khususnya pada tugas klasifikasi. *Learning rate* sebagai parameter dari *optimizer*, berfungsi dalam mengontrol langkah-langkah penyesuaian parameter yang dilakukan selama proses optimasi. *categorical\_crossentropy* dipilih sebagai *loss function* karena penelitian ini termasuk klasifikasi multi-kelas atau memiliki *output* lebih dari dua kelas. Jumlah *epoch* adalah 10 dan *batch size* sejumlah 32. Kombinasi lapisan serta *hyperparameter* pada arsitektur dilakukan secara berulang kali untuk mencapai hasil yang performa model yang maksimal. Rancangan arsitektur model dan kombinasi *hyperparameter* dapat dilihat pada Gambar 2 dan Tabel 3.



Gambar 2. Arsitektur Model

Tabel 3. Kombinasi Hyperparameter

No	Hyperparameter	Nilai
1	Optimizer	Adam
2	Learning Rate	0.001
3	Loss Function	categorical_crossentropy
4	Batch Size	32
5	Epochs	10

Pelatihan data dilakukan dengan percobaan berulang kali dengan empat skenario pembagian data yang berbeda. Skenario pembagian data dilakukan untuk menguji kemampuan model yang terbaik. Perbandingan hasil pelatihan model dapat dilihat pada Tabel 4.

**Tabel 4. Perbandingan Hasil Pelatihan Model**

Skenario	<i>Training Accuracy</i>	<i>Validation Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
90:5:5	95,9%	72,3%	71,4%	71,9%	71,0%
80:10:10	<b>96,4%</b>	<b>73,7%</b>	<b>72,1%</b>	<b>72,0%</b>	<b>72,8%</b>
70:15:15	96,2%	72,7%	68,8%	68,9%	68,0%
60:20:20	96,1%	72,0%	69,6%	69,5%	69,5%

Pengujian model dilakukan pada seluruh hasil skenario pelatihan model yang telah dilatih. Penelitian ini mengacu pada akurasi serta selisih akurasi pelatihan dengan akurasi validasi, sehingga penelitian ini menggunakan model dari pembagian data dengan 80:10:10. Tabel 4 menunjukkan pertimbangan yang dapat digunakan, yaitu akurasi pelatihan tertinggi, akurasi validasi yang wajar, dan keseimbangannya dengan hasil *precision*, *recall*, dan *F1-score*. *Training accuracy* yang diperoleh pada *epoch* terakhir atau ke-10 sebesar 0.9642 dan *validation accuracy* sebesar 0,7367. Selain itu, gambar juga menunjukkan bahwa *training loss* yang diperoleh pada *epoch* terakhir atau ke-10 sebesar 0,1457 dan *validation loss* sebesar 0,7315. Idealnya, perbedaan antara *training* dan *validation metrics* seharusnya seminimal mungkin untuk menunjukkan bahwa model mampu menggeneralisasi dengan baik ke data yang tidak dilihat sebelumnya. Perbedaan yang signifikan antara *validation accuracy* dan *training accuracy* menunjukkan kemungkinan adanya *overfitting* pada model. Dengan demikian, model mungkin terlalu terfokus pada data pelatihan dan kurang mampu untuk menggeneralisasi dengan baik ke data validasi.

Penelitian ini juga mempertimbangkan *precision*, *recall*, dan *F1-score* yang tercantum pada Tabel 4. *Precision* mengukur ketepatan prediksi positif dari model yang memperoleh angka 72,1%, *recall* mengukur kemampuan model dalam mendeteksi semua kasus positif yang memperoleh angka 72,0%, sedangkan *F1-score* memberikan keseimbangan antara *precision* dan *recall* yang memperoleh angka 72,8%. Ketiga metrik ini memiliki angka tertinggi pada pembagian data sebesar 80:10:10.

## 4. Hasil dan Diskusi

### 4.1. Klasifikasi Data

Klasifikasi data menggunakan model klasifikasi dan *tokenizer* yang telah dilatih sebelumnya dan disimpan dengan format .h5 dan .pkl. Proses klasifikasi menambahkan atribut sentimen yang berisi sentimen dengan skor probabilitas tertinggi. Sesuai dengan gambar, hasil eksekusi kode program sebelumnya menambahkan atribut *sentiment* pada dokumen yang berisi sentimen positif. Contoh hasil data yang telah diklasifikasikan dapat dilihat pada Gambar 3.

```

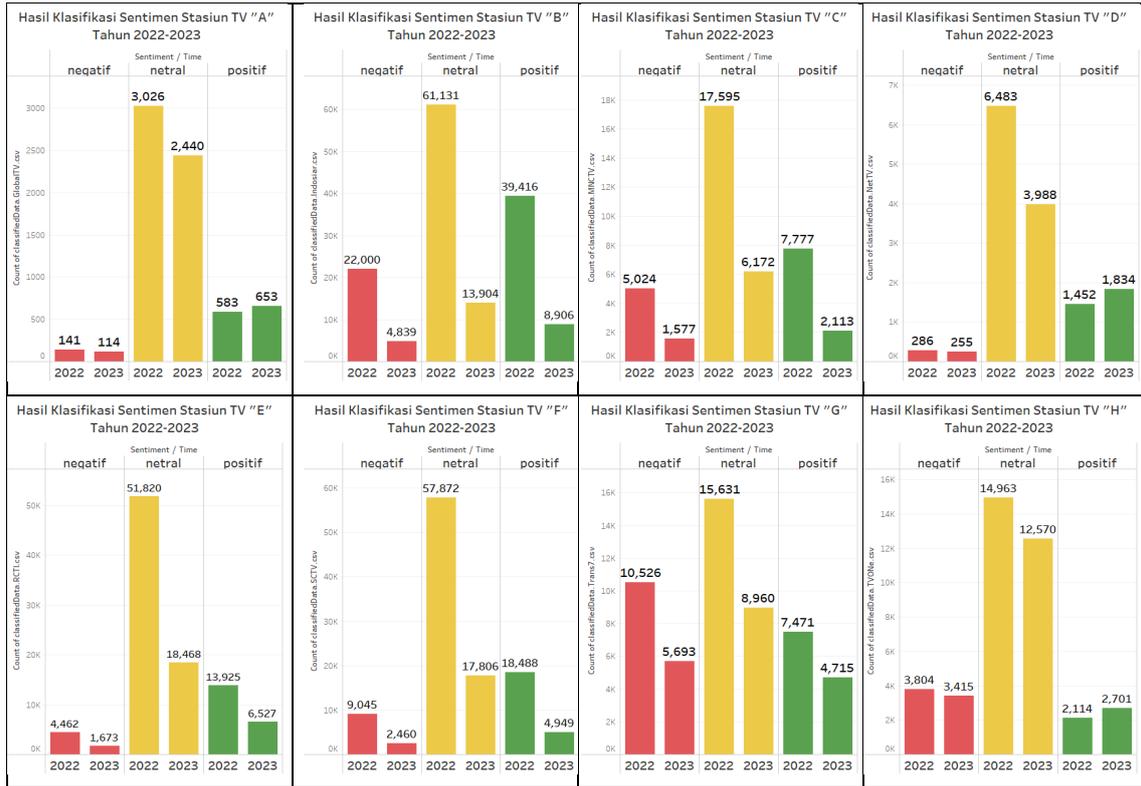
_id: ObjectId('65a0acda8d0b1a0b0cfa31fe')
created_at: "Tue Jan 04 15:51:12 +0000 2022"
id_str: 1478393585636622336
full_text: "██████████ bagus"
quote_count: 0
reply_count: 2
retweet_count: 0
favorite_count: 3
lang: "in"
user_id_str: 2344677949
conversation_id_str: 1478393585636622336
username: "██████████"
tweet_url: "https://twitter.com/██████████/status/1478393585636622336"
sentiment: "positif"

```

**Gambar 3. Contoh Hasil Klasifikasi Data**

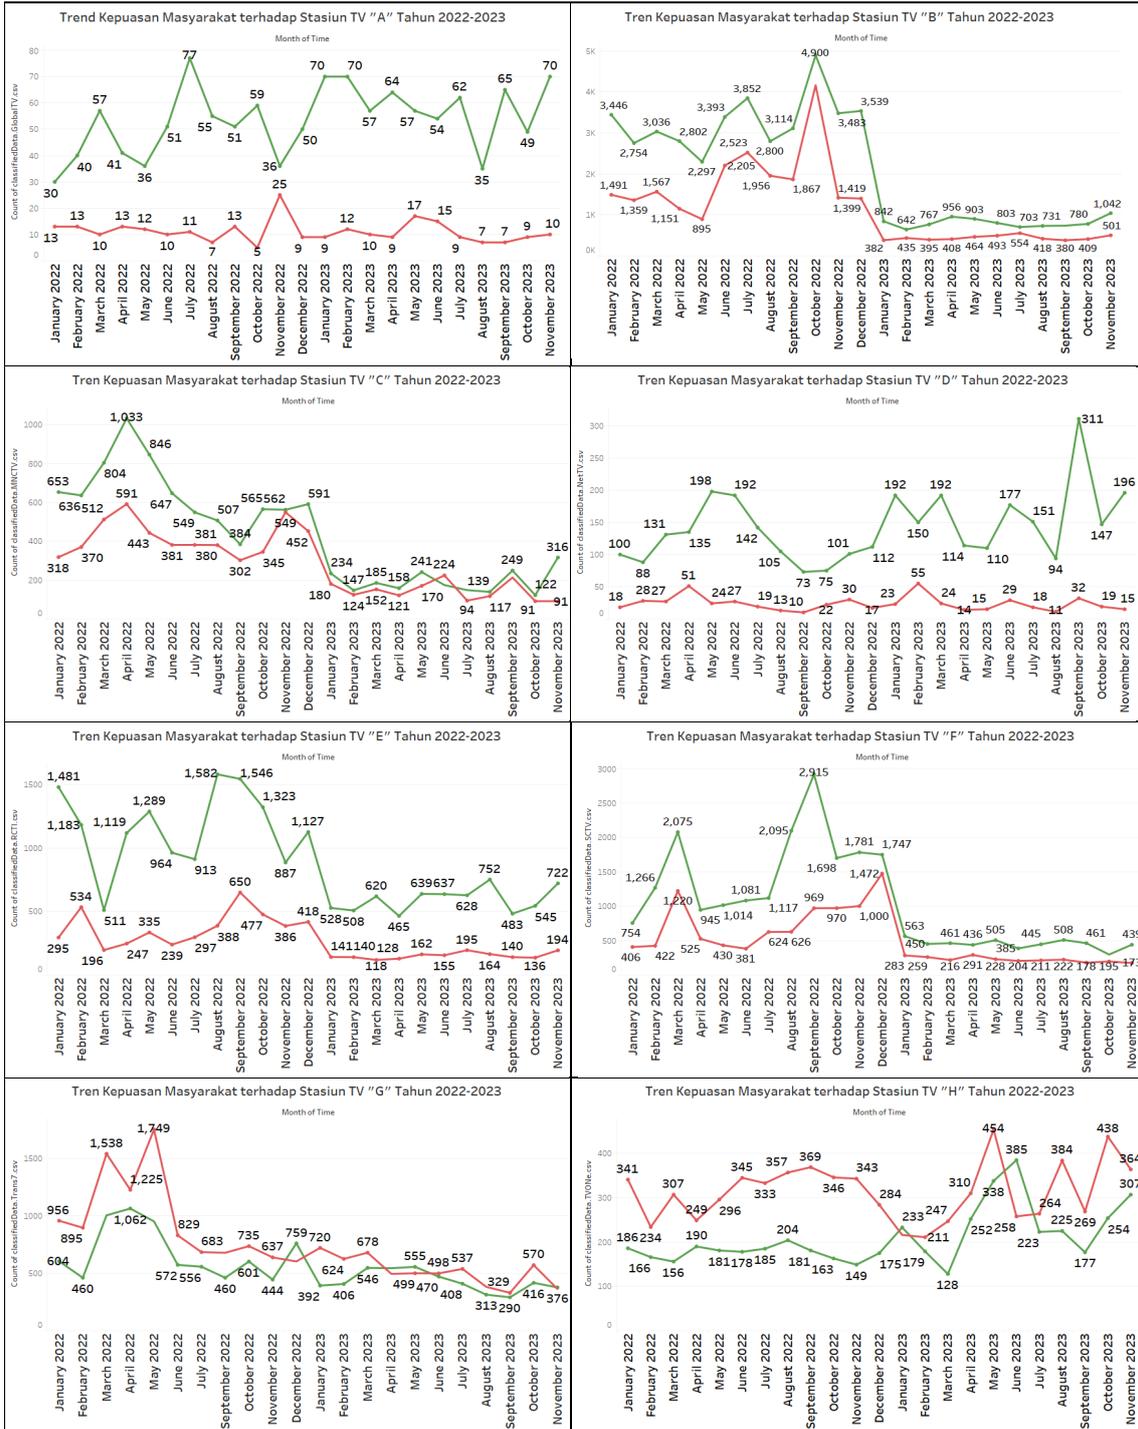
### 4.2. Visualisasi dan Analisis Data

Analisis sentimen merupakan tahap terakhir dari penelitian ini yang melibatkan visualisasi. Analisis yang digunakan adalah analisis perbedaan sentimen secara keseluruhan stasiun televisi nasional dan *trend* kepuasan masyarakat. Gambar 4 menampilkan perbandingan jumlah sentimen yang menunjukkan bahwa sentimen netral mendominasi sentimen masyarakat dengan total sentimen netral adalah 295.361, sentimen positif sebanyak 117.091, dan sentimen negatif sebanyak 73.641. Selain sentimen netral, dominasi sentimen positif dibandingkan sentimen negatif terjadi pada sebagian besar stasiun, kecuali Stasiun TV “G” dan Stasiun TV “H” yang cenderung mendapat sentimen negatif.



Gambar 4. Bar Chart Perbandingan Sentimen antar 8 Stasiun Televisi Nasional

Visualisasi *trend* kepuasan dilakukan untuk menjelaskan seputar kenaikan atau penurunan kualitas konten dari stasiun televisi tertentu dengan membandingkan data positif dan negatifnya. Gambar 5 menunjukkan *trend* pada delapan stasiun televisi, pada Stasiun TV “B”, Stasiun TV “E”, dan Stasiun TV “C”. Sentimen positif dan negatif memiliki pola yang sejajar dan tidak menunjukkan adanya peristiwa yang mengubah pola, berbeda dengan Stasiun TV “A” yang memiliki pola berbeda atau tidak selalu sejajar, terlihat pada penurunan dalam sentimen positif bersamaan dengan kenaikan sentimen negatif pada bulan November 2022. Hal ini memungkinkan adanya peristiwa atau faktor yang mempengaruhi persepsi masyarakat terhadap Stasiun TV “A” pada periode tersebut, begitu juga dengan keempat stasiun televisi lainnya, yaitu Stasiun TV “D” yang memiliki kenaikan drastis pada sentimen positif di September 2023. Stasiun TV “G” yang memiliki beberapa titik kenaikan sentimen positif yang melebihi sentimen negatif, salah satunya pada periode Desember 2022. Stasiun TV “H” yang memiliki kenaikan sentimen positif pada bulan Juni 2023 dengan jumlah tertinggi yaitu 385 sentimen positif dan secara bersamaan, penurunan terjadi pada sentimen negatif. Stasiun TV “F” yang memiliki kenaikan sentimen positif yang cukup drastis dalam periode Agustus hingga September 2022.



Gambar 5. Trend Kepuasan Masyarakat terhadap Televisi Nasional

### 5. Kesimpulan dan Saran

Penelitian ini menggunakan Bi-LSTM dan Word2Vec untuk mengklasifikasikan data yang didapat dari media sosial *Twitter*. Dari proses *training* hingga evaluasi, hasil terbaik yang didapat adalah skenario *splitting data* 80:10:10 dengan akurasi sebesar 96,4%, *precision* sebesar 72,1%, *recall* sebesar 72,0%, dan *F1-score* sebesar 72,8%. Hasil klasifikasi sentimen menunjukkan total sentimen netral adalah 295,361, sentimen positif sebanyak 117,091, dan sentimen negatif sebanyak 73,641 yang menunjukkan dominasi sentimen netral pada seluruh

stasiun televisi, dan diikuti dengan dominasi sentimen positif dibandingkan sentimen negatif pada sebagian besar stasiun, kecuali Stasiun TV “G” dan Stasiun TV “H” yang cenderung mendapat sentimen negatif. *Trend* kepuasan masyarakat terhadap stasiun televisi nasional bervariasi. Stasiun TV “B”, Stasiun TV “E”, dan Stasiun TV “C” memiliki sentimen positif dan negatif yang sejajar dan stabil. Stasiun TV “A” mengalami penurunan sentimen positif dan kenaikan negatif secara bersamaan pada November 2022, menunjukkan dominasi negatif pada periode tersebut. Stasiun TV “D” memiliki kenaikan sentimen positif yang drastis pada September 2023, sedangkan Stasiun TV “G” dan Stasiun TV “H” memiliki kenaikan sentimen positif pada beberapa titik seperti Desember 2022 dan Juni 2023 di tengah dominasi sentimen negatif. Stasiun TV “F” mengalami kenaikan sentimen positif yang signifikan dari Agustus hingga September 2022.

## Referensi

- [1] A. Abdullah and L. Puspitasari, “Media Televisi Di Era Internet,” *ProTVF*, vol. 2, no. 1, p. 101, 2018, doi: 10.24198/ptvf.v2i1.19880.
- [2] R. S. M. Permana and J. N. Mahameruaji, “Strategi Pemanfaatan Media Baru Net. TV,” *Jurnal Studi Komunikasi dan Media*, vol. 23, no. 1, p. 21, 2019, doi: 10.31445/jskm.2019.1770.
- [3] F. Junaedi, *Rating Naik, Etika Hilang*, 1st ed., Yogyakarta, Indonesia: Buku Litera, 2022.
- [4] N. H. Hamzah, E. F. F. Khomaeny, and M. Ulfa, “Tontonan Anak di Televisi: Paradoks dan Kontestasi Nilai Tontonan Anak di Media Televisi Nasional,” *Jurnal Obsesi: Jurnal Pendidikan Anak Usia Dini*, vol. 5, no. 2, pp. 1883–1893, 2021, doi: 10.31004/obsesi.v5i2.713.
- [5] Samsir, Ambiyar, U. Verawardina, F. Edi, and R. Watianthos, “Analisis Sentimen Pembelajaran Daring pada Twitter di Masa Pandemi COVID-19 Menggunakan Metode Naïve Bayes,” *Jurnal Media Informasi Budidarma*, vol. 5, no. 1, p. 149, 2021, doi: 10.30865/mib.v5i1.2604.
- [6] D. R. Alghifari, M. Edi, and L. Firmansyah, “Implementasi Bidirectional LSTM untuk Analisis Sentimen Terhadap Layanan Grab Indonesia,” *Jurnal Manajemen Informatika*, vol. 12, no.2, pp. 89–99, Sep. 2022, doi: 10.34010/jamika.v12i2.7764.
- [7] H. F. Fadli and A. F. Hidayatullah, “Identifikasi Cyberbullying pada Media Sosial Twitter Menggunakan Metode Klasifikasi Random Forest,” *Automata*, 2019. [Online]. Available: <https://journal.uii.ac.id/AUTOMATA/article/download/17364/10897>
- [8] A. K. Ni Komang, I. M. A. D. Suarjaya, and I. M. S. Raharja, “Classification of Public Figures Sentiment on Twitter Using Big Data Technology,” *Jurnal Informatika dan Telekomunikasi Teknik*, vol. 6, no. 1, pp. 157–169, 2022, doi: 10.31289/jite.v6i1.7329.
- [9] G. A. M. Kukuh Jaluwana, G. M. A. Sasmita, and I. M. A. D. Suarjaya, “Analysis of Public Sentiment Towards Government Efforts to Break the Chain of Covid-19 Transmission in Indonesia Using CNN and Bidirectional LSTM,” *Jurnal RESTI: Rekayasa Sistem dan Teknologi Informasi*, vol. 6, no. 4, pp. 511–520, 2022, doi: 10.29207/resti.v6i4.4055.
- [10] W. Widayat, “Analisis Sentimen Movie Review Menggunakan Word2Vec dan Metode LSTM Deep Learning,” *Jurnal Media Informasi Budidarma*, vol. 5, no. 3, p. 1018, 2021, doi: 10.30865/mib.v5i3.3111.
- [11] A. F. Hanif, T. B. Sasongko, and A. D. Laksito, “Perbandingan Kinerja LSTM, Bi-LSTM, dan GRU pada Klasifikasi Judul Berita Clickbait,” *Indonesian Journal of Computer Science*, vol. 12, no. 4, p. 2136, 2023.
- [12] W. K. Sari, D. P. Rini, R. F. Malik, and I. S. B. Azhar, “Multilabel Text Classification in News Articles Using Long-Term Memory with Word2Vec,” *Jurnal RESTI: Rekayasa Sistem dan Teknologi Informasi*, vol. 4, no. 2, pp. 276–285, 2020, doi: 10.29207/resti.v4i2.1655.
- [13] D. I. Af'idah, D. Dairoh, S. F. Handayani, R. W. Pratiwi, and S. I. Sari, “Sentimen Ulasan Destinasi Wisata Pulau Bali Menggunakan Bidirectional Long Short Term Memory,” *Matrik: Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, vol. 21, no. 3, pp. 607–618, 2022, doi: 10.30812/matrik.v21i3.1402.

- [14] D. I. Puteri, "Implementasi Long Short Term Memory (LSTM) dan Bidirectional Long Short Term Memory (BiLSTM) dalam Prediksi Harga Saham Syariah," *Euler: Jurnal Ilmiah Matematika, Sains dan Teknologi*, vol. 11, no. 1, pp. 35–43, 2023, doi: 10.34312/euler.v11i1.19791.
- [15] M. D. Rahman, A. Djunaidy, and F. Mahananto, "Penerapan Weighted Word Embedding pada Pengklasifikasian Teks Berbasis Recurrent Neural Network untuk Layanan Pengaduan Perusahaan Transportasi," *Jurnal Sains dan Seni ITS*, vol. 10, no. 1, 2021, doi: 10.12962/j23373520.v10i1.56145.