

# Sentiment Analysis of AI-Driven Job Automation in Indonesia: Integrating LSTM, BERTopic, and Time-Series Forecasting for Job Displacement Risk Prediction

Valencia Elcheiana Irawan <sup>1\*</sup>, Adi Suryaputra Paramita <sup>2\*</sup>

\* Information Systems for Business, Universitas Ciputra Surabaya  
[velcheiana@student.ciputra.ac.id](mailto:velcheiana@student.ciputra.ac.id) <sup>1</sup>, [adi.suryaputra@ciputra.ac.id](mailto:adi.suryaputra@ciputra.ac.id) <sup>2</sup>

## Article Info

### Article history:

Received 2026-01-22  
Revised 2026-03-03  
Accepted 2026-04-08

### Keyword:

*Sentiment Analysis,  
Long Short-Term Memory,  
BERTopic,  
Job Automation,  
Job Displacement,  
Artificial Intelligence.*

## ABSTRACT

The rapid advancement of artificial intelligence (AI) has intensified public concerns regarding job automation and potential workforce displacement. While previous studies often examine sentiment, topic modeling, or temporal trends separately, this study integrates sentiment classification, topic modeling, and time-series forecasting to provide a comprehensive analysis of public perceptions in Indonesia. From an initial collection of 1.026 tweets, 966 validated Indonesian-language tweets from Twitter/X collected between 2024 and 2026 were retained for analysis. Sentiment labeling was conducted using a weakly supervised lexicon-based approach, followed by classification with a Long Short-Term Memory (LSTM) model. The model achieved 72% accuracy with a weighted F1-score of 0.72 and demonstrated strong performance in detecting negative sentiment, achieving a recall of 0.83. BERTopic modeling revealed dominant concerns related to job replacement, automation risks, vulnerable professions, and skill adaptation in the digital era. Furthermore, ARIMA-based time-series forecasting indicates that negative sentiment trends are likely to persist in the near future. This study contributes methodologically by integrating deep learning, topic modeling, and temporal forecasting within a unified framework to better understand evolving public risk perceptions of AI-driven job automation in Indonesia.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

## I. PENDAHULUAN

Perkembangan *Artificial Intelligence (AI)* beberapa tahun terakhir ini telah memicu terjadinya perubahan pada berbagai sektor pekerjaan, mulai dari pekerjaan yang bersifat repetitif hingga yang bersifat keterampilan kognitif [1]. Menurut World Economic Forum, pada tahun 2027 diprediksi akan ada 83 juta pekerjaan yang hilang disebabkan oleh otomisasi, sementara ada 69 juta pekerjaan baru yang akan muncul. Hal ini memunculkan berbagai pendapat publik mengenai dampak *AI* terhadap dunia kerja, terkhusus mengenai risiko penggantian pekerjaan manusia atau *job displacement* serta kebutuhan *upskilling* bagi tenaga kerja [2].

Platform media sosial seperti Twitter/X kemudian berfungsi sebagai wadah utama bagi masyarakat untuk mengungkapkan pandangan, kekhawatiran, maupun harapan mereka terhadap perkembangan teknologi *AI*. Namun, pendapat mereka sulit dipahami secara menyeluruh jika hanya

melalui pendekatan kualitatif konvensional dikarenakan persepsi mereka yang sangat beragam dan dinamis.

Di Indonesia, penelitian mengenai persepsi dan sentimen publik masih cenderung terbatas, sebagian besar lebih berfokus pada dampak ekonomi *AI* secara makro, seperti produktivitas atau tingkat pengangguran. Serta, penelitian yang menggabungkan analisis sentimen, pemodelan topik, dan analisis temporal untuk memahami dinamika risiko *job displacement* masih sangat terbatas.

Analisis sentimen merupakan pendekatan komputasional untuk mengkaji sentimen, opini, dan emosi terhadap suatu objek yang direpresentasikan dalam bentuk teks [3]. Analisis ini digunakan untuk mengidentifikasi atribut serta komponen yang ada di dalamnya yang kemudian digunakan untuk mengelompokkan teks tersebut ke dalam kategori bermakna positif, netral, atau negatif. Analisis sentimen dapat dilakukan dengan berbagai metode pembelajaran mesin, salah satunya

adalah LSTM (Long Short-Term Memory). LSTM memiliki kapabilitas dalam menangkap dan memahami urutan kata dan hubungan antar kata dalam sebuah kalimat. Analisis sentimen media sosial banyak yang telah mengaplikasikan LSTM secara luas, hasilnya pun menunjukkan performa yang lebih unggul apabila dibandingkan dengan metode tradisional lain yang menggunakan fitur statis [4].

Pendekatan BERTopic merupakan metode pemodelan topik dengan cara mengidentifikasi dan mengombinasikan representasi topik yang relevan dengan pembobotan beragam TF-IDF berbasis kelas [5]. Dalam analisis diskursus publik berbasis media sosial, metode ini semakin banyak digunakan.

Selanjutnya, pendekatan deret waktu (time-series analysis) digunakan untuk memahami perubahan opini publik dari waktu ke waktu. Peramalan deret waktu dengan model ARIMA dapat menghasilkan peramalan berdasarkan pola data secara historis [6]. Hal ini memungkinkan peneliti untuk memproyeksikan kecenderungan sentimen ke periode yang akan datang. Dalam konteks otomatisasi pekerjaan oleh AI, pendekatan ini berguna untuk memahami bagaimana persepsi risiko job displacement berkembang dan akan berpotensi berlanjut atau tidak.

Oleh karena itu, penelitian ini bertujuan untuk menganalisis sentimen publik di Indonesia terhadap otomatisasi pekerjaan oleh AI menggunakan model klasifikasi LSTM, kemudian mengidentifikasi isu-isu utama yang membentuk sentimen publik dengan pemodelan topik BERTopic, serta menganalisis dinamika persepsi publik terhadap risiko *job displacement* dari waktu ke waktu menggunakan pendekatan deret waktu. Diharapkan hasil dari penelitian ini dapat memberikan manfaat dalam hal akademis dengan memperkaya kajian analisis sentimen. Selain itu, juga memberikan manfaat bagi pembuat kebijakan, pelaku industri, dan pemangku kepentingan dalam menyusun strategi adaptasi untuk tenaga kerja dalam menghadapi tantangan otomatisasi pekerjaan berbasis AI.

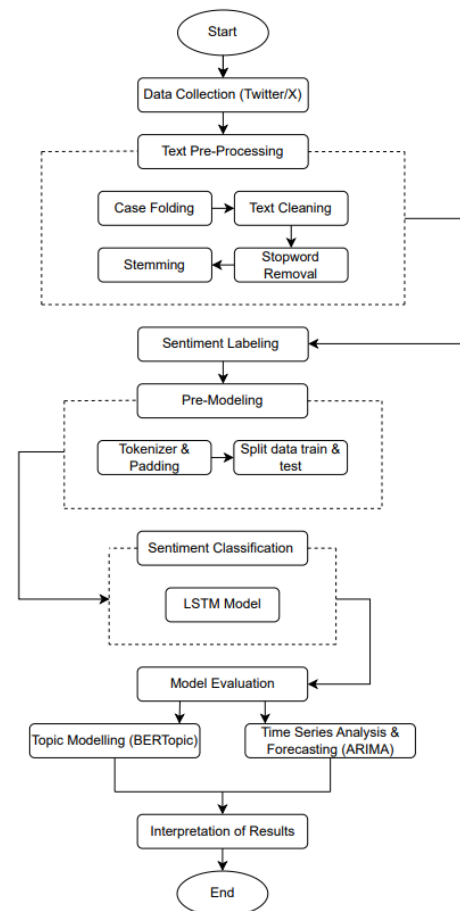
## II. METODE

Metode penelitian merupakan rangkaian prosedur ilmiah yang disusun secara sistematis yang digunakan untuk mengumpulkan, menganalisis, dan menginterpretasikan data, yang selanjutnya dapat digunakan untuk menjawab sebuah pertanyaan atau menguji hipotesis dalam sebuah penelitian. Di dalamnya akan mencakup langkah tertentu yang menjadi pedoman dalam pelaksanaan penelitian agar mendapatkan hasil yang bersifat valid dan dapat dipertanggungjawabkan [7]. Berikut alur penelitian yang dilakukan pada penelitian ini, dapat dilihat pada Gambar 1.

### A. Data Collection

Data yang akan digunakan pada penelitian ini merupakan data yang diperoleh dari media sosial Twitter/X. Dataset dikumpulkan menggunakan metode *scraping* menggunakan Application Programming Interface (API) dengan bantuan library *tweet-harvest* versi 2.6.1 berbasis bahasa pemrograman Python. Pengumpulan data dilakukan

berdasarkan beberapa kata kunci atau parameter pencarian yang relevan dengan topik AI, pekerjaan, dan otomatisasi. Seperti, “AI”, “kecerdasan buatan”, “otomatisasi pekerjaan”, “penggantian pekerjaan”, “job displacement”, serta “PHK akibat AI”. Parameter pencarian juga difilter menggunakan pengaturan bahasa (*lang:id*). Periode pengambilan data mencakup rentang waktu dari Januari 2024 hingga Januari 2026. Data diambil secara acak dan bertahap. Kemudian, dari total 1.026 tweet yang berhasil dikumpulkan pada tahap awal, setelah melewati proses pengecekan serta pembersihan data untuk menghilangkan data yang sama atau duplikat maupun data yang kurang relevan, diperoleh 966 tweet yang digunakan sebagai dataset penelitian [8].



Gambar 1. Diagram Alur Metode Penelitian

### B. Pre-Processing

Tahapan *preprocessing* dilakukan untuk meningkatkan kualitas data sebelum dianalisis lebih lanjut. Hal ini dilakukan karena data yang diambil dari media sosial umumnya bersifat tidak terstruktur dan masih mengandung banyak *noise*. Seluruh tahapan preprocessing dalam penelitian ini diimplementasikan menggunakan bahasa pemrograman Python dengan bantuan beberapa library pendukung, antara lain *pandas* untuk manipulasi data, *re* (regular expression) untuk pembersihan teks, *NLTK* dan *Sastrawi* untuk tokenisasi

serta lemmatization bahasa Indonesia, serta *scikit-learn* untuk proses normalisasi dan pemisahan data. Proses pengolahan teks dilakukan menggunakan Google Colab. Adapun beberapa tahapan *pre-processing* yang dilakukan dalam penelitian ini meliputi langkah berikut.

#### 1) Case Folding

*Case folding* merupakan tahap untuk mengubah bentuk huruf menjadi seragam [9]. Dalam penelitian ini dilakukan perubahan seluruh teks menjadi huruf kecil (*lowercase*). Langkah ini bertujuan untuk meminimalisir perbedaan makna akibat penggunaan huruf besar dan huruf kecil dalam suatu teks, sehingga kata yang sama dapat diperlakukan secara konsisten.

#### 2) Text Cleaning

*Text Cleaning* merupakan tahapan pembersihan validasi kata yang tidak diperlukan, guna meminimalkan gangguan pada proses klasifikasi [10]. Dalam penelitian ini, *text cleaning* dilakukan dengan menghilangkan beberapa elemen yang tidak relevan terhadap proses analisis sentimen, seperti URL, *mention* pengguna, tagar, angka, tanda baca, emoji, dan simbol-simbol lainnya. Langkah ini bertujuan untuk mengurangi *noise* pada data sehingga model dapat mengambil informasi yang berkaitan dengan sentimen dengan lebih optimal.

#### 3) Stopword Removal

*Stopword Removal*, salah satu metode penghapusan kata-kata umum yang dianggap paling sering muncul, namun tidak memiliki makna penting dan tidak memberikan pengaruh yang berarti terhadap makna kalimat atau teks, seperti “dan”, “yang”, “di”, dan “ke” [11]. Proses ini dapat meningkatkan performa model dengan mengurangi jumlah kata yang akan diproses.

#### 4) Stemming

*Stemming* merupakan proses yang bertujuan untuk mengonversi kata berimbuhan ke dalam bentuk dasar dasarnya. Proses ini berperan dalam menekan variasi kata yang muncul, sehingga representasi teks menjadi lebih seragam, karena sebuah kata dengan bentuk dasar yang sama akan diperlakukan sebagai satu entitas. Contohnya kata “menggantikan”, “digantikan”, dan “penggantian” akan diubah menjadi kata dasar “ganti” [8].

### C. Sentiment Labeling

Dataset tidak memiliki label sentimen awal, maka dari itu perlu dilakukan pelabelan menggunakan pendekatan *weakly supervised* berbasis leksikon sentimen. Pendekatan ini dipilih karena studi terdahulu menunjukkan bahwa metode berbasis leksikon efektif dalam mengidentifikasi orientasi sentimen berdasarkan kemunculan kata kunci tertentu, serta sering digunakan sebagai dasar pengembangan metode berbasis machine learning dan deep learning [12]. Dengan pendekatan ini, setiap tweet diberi label sentimen yang dikelompokkan ke

dalam tiga kategori, yaitu negatif, netral, dan positif berdasarkan skor polaritas yang diperoleh dari kamus sentimen. Label ini berfungsi sebagai *ground truth* awal untuk melatih model dalam mengenali pola sentimen dalam data teks.

### D. Pre-Modeling

Tahapan *pre-modeling* dilakukan untuk menyiapkan data teks yang telah melalui tahap *pre-processing* dan pelabelan sentimen agar dapat digunakan sebagai *input* pada model pembelajaran yang lebih mendalam. Pada tahap ini, teks yang masih berbentuk data string akan diubah menjadi representasi numerik, karena model Long Short-Term Memory (LSTM) hanya dapat memproses data dalam bentuk angka. Selain itu, tahapan ini juga bertujuan untuk memastikan kesesuaian format data serta pembagian data yang sistematis untuk keperluan pelatihan dan pengujian model. Adapun beberapa tahapan *pre-modeling* yang dilakukan dalam penelitian ini meliputi langkah berikut.

#### 1) Tokenizing & Padding

*Tokenizing* merupakan proses mengonversi teks menjadi unit yang lebih kecil, dapat berupa kata ataupun token [13]. Tahapan ini dibutuhkan dalam penelitian ini karena model LSTM membutuhkan input berupa urutan token. Tokenisasi memungkinkan setiap kata dalam sebuah kalimat dapat direpresentasikan sebagai bagian dari urutan data yang dapat dipelajari oleh model. Selanjutnya, *padding* bertujuan untuk menyeragamkan panjang setiap urutan token [8]. Hal ini dilakukan karena panjang teks untuk setiap tweet umumnya berbeda-beda. Maka dari itu, teks yang lebih pendek akan ditambahkan token khusus hingga mencapai panjang maksimum yang telah ditentukan sehingga pada akhirnya data akan memiliki dimensi yang sama dan dapat diproses secara efisien oleh model LSTM.


#### 2) Split Data Train & Test

Dataset dipisahkan ke dalam dua bagian, yaitu data latih (*train*) dan data uji (*test*). Data latih dimanfaatkan untuk melatih model agar mampu mengidentifikasi pola-pola dalam data serta mempelajari keterkaitan antar fitur. Sementara, data uji dimanfaatkan untuk mengukur performa model menggunakan data baru yang belum pernah dilihat sebelumnya [14].

### E. Sentiment Classification Using LSTM

Analisis sentimen dilakukan dengan menggunakan metode *Long Short-Term Memory* (LSTM) karena metode ini memiliki kemampuan dalam memproses data teks secara berurutan serta menangkap hubungan antar kata dalam suatu kalimat. LSTM merupakan metode yang dikembangkan untuk mengatasi permasalahan *vanishing gradient* pada metode (*Recurrent Neural Network*) RNN. Metode LSTM hanya memiliki perbedaan struktur pada proses *hidden state* jika dibandingkan dengan metode RNN. Proses *hidden state* ini melalui empat *gate*, yaitu *forget gate*, *input gate*, *cell state*,

dan *output gate* [15]. Metode LSTM dibangun dengan lapisan *embedding* untuk merepresentasikan kata, kemudian diikuti oleh lapisan LSTM dan *dropout* untuk mengurangi risiko *overfitting*.



Gambar 2. Arsitektur LSTM

Terdapat juga lapisan *dense* dengan fungsi aktivasi *softmax* untuk mengklasifikasikan tiga kelas sentimen. Dataset dibagi menjadi data latih (*train*) dan data uji (*test*) dengan rasio tertentu. Hasil pelatihan model LSTM selanjutnya divisualisasikan dalam bentuk grafik akurasi dan *loss* untuk menunjukkan perkembangan kinerja model pada setiap tahapan pelatihan dengan jumlah *epoch* yang berbeda.

#### F. Model Evaluation

Setelah proses pemodelan dilakukan, analisis model dilanjutkan dengan kinerja model dievaluasi melalui metrik akurasi, *precision*, *recall*, dan *F1-score*. Selain itu, *confusion matrix* juga dimanfaatkan untuk mengevaluasi kesalahan klasifikasi pada setiap kategori sentimen. Tahap evaluasi ini dilakukan untuk memastikan bahwa model menghasilkan prediksi yang dapat diinterpretasikan sebelum digunakan pada analisis lanjutan, termasuk untuk pemodelan topik dan *time-series forecasting*.

#### G. Topic Modeling Using BERTopic

Untuk mengidentifikasi isu-isu utama yang membentuk sentimen publik, penelitian ini memanfaatkan pemodelan topik menggunakan BERTopic, dimana metode ini menggabungkan representasi embedding teks dengan pembobotan *class-based TF-IDF (c-TF-IDF)* [16]. Representasi embedding kalimat diperoleh menggunakan model *Sentence Transformer* "all-MiniLM-L6-v2". Pemodelan topik diterapkan pada tweet dengan sentimen negatif dan netral. Hal ini dikarenakan kedua kategori tersebut dianggap paling menggambarkan persepsi risiko terhadap otomatisasi pekerjaan oleh AI.

#### H. Time-Series Analysis and Forecasting

*Time-Series Analysis and Forecasting* dalam penelitian ini dilakukan untuk mempelajari dinamika sentimen publik dari waktu ke waktu. Skor sentimen agregat dihitung secara periodik, kemudian divisualisasikan untuk mengamati tren sentimen. Untuk memprediksi kecenderungan persepsi risiko *job displacement* pada periode yang akan datang digunakan metode peramalan deret waktu berbasis ARIMA.

Pemilihan model ARIMA didasarkan pada karakteristik data yang bersifat univariat dan menunjukkan ketergantungan temporal antar periode pengamatan. Studi terdahulu menunjukkan bahwa ARIMA efektif dalam memprediksi tren berbasis data historis, termasuk dalam konteks analisis sentimen dan data media sosial [17]. Dari studi tersebut, ditemukan bahwa integrasi analisis sentimen dengan model ARIMA mampu menghasilkan performa prediksi yang baik dengan tingkat kesalahan yang relatif rendah.

Selanjutnya, hasil dari analisis ini berfungsi untuk menginterpretasikan arah perkembangan sentimen publik terhadap otomatisasi pekerjaan oleh AI.

### III. HASIL DAN PEMBAHASAN

Pembahasan hasil penelitian ini diawali oleh tahap pengumpulan dataset. Selanjutnya, data yang telah diperoleh akan dilakukan proses pengolahan terlebih dahulu sebelum tahap pemodelan untuk memperoleh hasil yang lebih optimal.

#### A. Data Collection

Proses pengumpulan dataset dilakukan dengan metode *web scraping* pada media sosial X (Twitter) yang memanfaatkan bahasa pemrograman Python, library *tweet-harvest* versi 2.6.1, serta *access token* API. Proses pengambilan data dilakukan berdasarkan sejumlah parameter pencarian yang relevan dengan topik AI, pekerjaan, dan otomatisasi dalam rentang waktu 1 Januari 2024 hingga 1 Januari 2026, dengan filter bahasa Indonesia (*lang:id*).

```
# Crawl Data
filename = "datascraping.csv"
search_keyword = "AI menggantikan pekerjaan lang:id until:2026-01-01 since:2024-01-01"
limit = 700

!pipx -y tweet-harvest@2.6.1 -o "[filename]" -s "[search_keyword]" --tab "LATEST" -l (limit) --token (twitter_auth_token)
... Opening twitter search page...

-- Scrolling... (1) (2) (3)
Filling in keywords: AI menggantikan pekerjaan lang:id until:2026-01-01 since:2024-01-01
(4) (5)Created new directory: /content/tweets-data

Your tweets saved to: /content/tweets-data/datascraping.csv
Total tweets saved: 10

-- Scrolling... (1)
Your tweets saved to: /content/tweets-data/datascraping.csv
Total tweets saved: 20

-- Scrolling... (1)
Your tweets saved to: /content/tweets-data/datascraping.csv
Total tweets saved: 30

-- Scrolling... (1) (2)
Your tweets saved to: /content/tweets-data/datascraping.csv
Total tweets saved: 50

-- Scrolling... (1) (2)
Your tweets saved to: /content/tweets-data/datascraping.csv
Total tweets saved: 70
```

Gambar 3. Proses Scraping Dataset

Terdapat keterbatasan API X dalam proses *scraping* data sehingga batas maksimum tweet yang ditetapkan pada sekali sesi *scraping*. Oleh karena itu, pengumpulan data dilakukan secara bertahap dan data yang telah diperoleh kemudian dikompilasi ke dalam sebuah file CSV. Proses ini menghasilkan data sekitar 1.026 kumpulan *raw* data yang tersimpan ke dalam file "datascraping.csv" di direktori "/content/tweets-data/".

Berikut adalah contoh gambar dan tabel dataset hasil *scraping* yang berhasil dikumpulkan menggunakan beberapa

kata kunci yang relevan dengan topik AI, pekerjaan, dan otomatisasi. Kata kuncinya meliputi, “AI”, “kecerdasan buatan”, “otomatisasi pekerjaan”, “penggantian pekerjaan”, “job displacement”, serta “PHK akibat AI”.

```
num_tweets = len(df)
print(f"Jumlah tweet: {num_tweets}")
```

	full_text	created_at
0	Menurut riset terbaru dari Goldman Sachs sekit...	2024-01-04 06:43:03
1	@OmonganS4MP4Ah Halo bang santai aja lah ya ki...	2024-01-04 07:13:03
2	AI memang berpotensi menggantikan sebagian pek...	2024-01-05 10:39:20
3	Techbros dan STEMoids yang membela AI art ini ...	2024-01-06 11:47:51
4	4) Penentang AI: Mayoritas dari artist graphic...	2024-01-06 20:27:04

Gambar 4. Hasil Scraping Dataset

TABEL I  
5 TERATAS ISI DATASET

No	Full Text
1	Menurut riset terbaru dari Goldman Sachs sekitar 300 juta pekerjaan di seluruh dunia berisiko digantikan oleh kecerdasan buatan (AI). Studi dari McKinsey Global Institute juga menguatkan pandangan ini menunjukkan bahwa AI dapat menggantikan pekerjaan manusia
2	@OmonganS4MP4Ah Halo bang santai aja lah ya kita dalam beropini. Sebetulnya kami sebagai penggiat seni sama sekali ngga takut akan digantikan oleh AI. Bisa diliat hasil AI ini banyak kecacatan
3	AI memang berpotensi menggantikan sebagian pekerjaan manusia. Wajar sih kalo kita kadang overthinking. Tapi yang jadi poinnya menurutku bagaimana kita bisa belajar sesuatu yang baru. Menerapkan esensi long life learning di kehidupan sehari-hari.
4	Techbros dan STEMoids yang membela AI art ini tahukah bahwa AI juga bisa aja menggantikan pekerjaan mereka? Orang aplikasi flutter aja bisa kok pake GPT (ya walaupun hasilnya ga optimal banget sama dengan AI art) tapi kalo employer pada mau itu gimana?
5	Penentang AI: Mayoritas dari artist graphic designer dan ilustrator yg khawatir dgn maraknya AI berbasis prompt yg akan menggantikan pekerjaan mereka. Pengguna AI: Mayoritas pengusaha data analyst dan advokat yg memang memanfaatkan AI utk kemudahan pekerjaannya.

Dari total 1.026 dataset yang diperoleh melalui proses *scraping*, selanjutnya dilakukan pengecekan dan pembersihan untuk menghapus data duplikat serta data yang tidak relevan. Setelah proses tersebut, diperoleh sebanyak 966 dataset yang valid, layak dan siap digunakan untuk tahap analisis [18].

Data tersebut kemudian di impor kembali ke Google Colab dan selanjutnya dimanfaatkan dalam tahapan analisis sentimen dengan metode klasifikasi Long Short-Term Memory (LSTM), BERTopic, dan Time-Series Forecasting.

**B. Pre-Processing**

Tahapan *pre-processing* dataset dilakukan sebelum analisis dengan tujuan untuk membersihkan dan menstandarisasi data teks. Pada penelitian ini, *pre-processing* meliputi sejumlah tahapan sebagai berikut.

- 1) *Case Folding*: Mengonversi keseluruhan teks menjadi huruf kecil (*lowercase*).
- 2) *Text Cleaning*: Menghapus elemen-elemen yang tidak relevan, seperti URL, *mention* pengguna, tagar, angka, tanda baca, emoji, dan karakter simbol lainnya.
- 3) *Stopword Removal*: Menghilangkan kata-kata umum yang kerap muncul namun tidak memiliki makna penting dan tidak memiliki kontribusi signifikan terhadap makna kalimat atau teks.
- 4) *Stemming*: Mengubah kata-kata yang berimbuhan menjadi bentuk dasarnya.

Berikut adalah tahapan dari *pre-processing* dataset yang dapat dilihat pada Tabel II.

TABEL II  
TAHAPAN PRE-PROCESSING

Tahapan Pre-processing	Data Pre-processing
Case Folding	menurut riset terbaru dari goldman sachs sekitar 300 juta pekerjaan di seluruh dunia berisiko digantikan oleh kecerdasan buatan (ai). studi dari mckinsey global institute juga menguatkan pandangan ini menunjukkan bahwa ai dapat menggantikan pekerjaan manusia
Text Cleaning	menurut riset terbaru dari goldman sachs sekitar juta pekerjaan di seluruh dunia berisiko digantikan oleh kecerdasan buatan ai studi dari mckinsey global institute juga menguatkan pandangan ini menunjukkan bahwa ai dapat menggantikan pekerjaan manusia
Stopword Removal	riset terbaru goldman sachs juta pekerjaan seluruh dunia berisiko digantikan kecerdasan buatan ai studi mckinsey global institute menguatkan pandangan menunjukkan ai menggantikan pekerjaan manusia
Stemming	riset terbaru goldman sachs juta pekerjaan seluruh dunia berisiko digantikan kecerdasan buatan ai studi mckinsey global institute menguatkan pandangan menunjukkan ai menggantikan pekerjaan manusia

Pada Tabel II di atas ditampilkan hasil dari tahap *pre-processing*, yang mencakup proses penyeragaman huruf, penghapusan simbol, eliminasi kata-kata yang tidak berkontribusi terhadap makna teks, serta penyederhanaan kata ke dalam bentuk dasarnya. Hasil proses ini menghasilkan data

teks yang lebih bersih dan konsisten sehingga mendukung proses analisis sentimen dan pemodelan selanjutnya.

### C. Sentiment Labeling

Pelabelan sentimen pada penelitian ini dilakukan dengan tujuan menghasilkan kelas sentimen awal yang akan digunakan sebagai *ground truth* dalam pelatihan dan evaluasi model klasifikasi sentimen berbasis Long Short-Term Memory (LSTM). Pelabelan ini menggunakan pendekatan *lexicon-based sentiment labelling* secara *weakly supervised* [19]. Hal ini dilakukan karena dataset Twitter/X yang telah berhasil *discrepating* tidak memiliki label sentimen awal, sehingga pendekatan ini memungkinkan proses pelabelan secara otomatis dengan memanfaatkan daftar kata yang dikelompokkan dengan sentimen positif dan negatif.

Langkah awal dalam pelabelan sentimen adalah dengan menganalisis frekuensi kata dalam data teks yang telah melalui proses *pre-processing*. Keseluruhan kata digabung dan frekuensi kemunculannya dihitung menggunakan metode *word frequency counting*. Hasil analisis 30 kata dengan frekuensi yang paling sering muncul terlihat pada Tabel III.

TABEL III  
TAHAPAN LABELING SENTIMENT

Words	Frequency
'ai'	1410
'kerja'	1203
'ganti'	805
'manusia'	439
'teknologi'	150
'bantu'	119
'orang'	92
'takut'	83
'robot'	77
'kembang'	76
'hilang'	73
'cerdas'	66
'phk'	61
'cipta'	60
'data'	58
'mudah'	57
'ancam'	52
'krisis'	52
'ajar'	51
'guna'	48
'usaha'	47
'butuh'	47
'ambil'	47
'tugas'	47
'peran'	44
'bidang'	44
'ubah'	43
'jenis'	43
'khawatir'	42
'dampak'	42

Berdasarkan hasil analisis tersebut, disusun 2 himpunan kata sentimen positif dan kata sentimen negatif. Daftar kata

positif mencakup kata-kata yang merepresentasikan manfaat atau peluang dari AI, seperti “*bantu*”, “*mudah*”, “*kembang*”, “*guna*”, “*cipta*”, dan “*usaha*”. Sedangkan, daftar kata negatif mencakup kata-kata yang merepresentasikan risiko dan kekhawatiran publik, seperti “*ganti*”, “*phk*”, “*hilang*”, “*ancam*”, “*takut*”, “*robot*”, dan “*krisis*”.

Proses pelabelan dilakukan dengan cara menghitung skor sentimen dalam setiap teks berdasarkan kemunculan kata dalam kedua daftar tersebut. Kata positif akan menambah skor satu, sedangkan kata negatif akan mengurangi skor satu. Secara matematis, skor sentimen untuk sebuah teks dapat dirumuskan sebagai berikut:

$$\text{Skor Sentimen} = \sum_{i=1}^n P_i - \sum_{j=1}^m N_j$$

$P_i$  merupakan kata positif dan  $N_j$  merupakan kata negatif dalam satu teks. Setelah nilai skor diperoleh, label sentimen selanjutnya ditentukan dengan aturan berikut:

- Skor > 0 → sentimen positif
- Skor = 0 → sentimen netral
- Skor < 0 → sentimen negative

```
def label_sentiment(text):
    score = 0
    for w in positive_words:
        if w in text:
            score += 1
    for w in negative_words:
        if w in text:
            score -= 1

    if score > 0:
        return 'positive'
    elif score < 0:
        return 'negative'
    else:
        return 'neutral'


df['sentiment'] = df['clean_text'].apply(label_sentiment)
df['sentiment'].value_counts()

count
sentiment
negative    587
neutral     235
positive    144

dtypes: int64

full_text sentiment
244    Tapi please jangan jadin AI sebagai sebuah an...    neutral
467    Reminder. AI itu untuk membantu pekerjaan manu...    negative
836    Hari ini gue mau santai ga kerja karena kemari...    neutral
557    solusinya! Pesan yang kami bawa: Jangan takut...    negative
70     Kenyataanya manusia mulai mengambil alih tugas...    negative
```

Gambar 5. Hasil Sentiment Labeling



Gambar 6. Grafik Hasil Sentimen

Hasil pelabelan menunjukkan bahwa mayoritas data diklasifikasikan ke dalam kategori sentimen negatif dan netral, sedangkan sentimen positif relatif lebih kecil. Distribusi ini menunjukkan dominasi ekspresi kekhawatiran dan sikap kekhawatiran masyarakat terhadap otomatisasi pekerjaan oleh AI.

D. Pre-Modeling

Tahap lanjutan setelah proses preprocessing teks dan pelabelan sentimen selesai dilakukan adalah tahap *pre-modeling*. Pada tahap ini, data teks yang masih berupa kata dan kalimat akan dikonversi menjadi bentuk numerik yang dapat diproses oleh model. Selain itu, tahap ini memiliki tujuan untuk menyiapkan data agar siap digunakan dalam proses pelatihan serta evaluasi model secara terstruktur.

1) Tokenizing & Padding

Proses tokenizing dilakukan menggunakan Tokenizer dari dengan batas kosakata sebanyak 8.000 kata. Batasan ini difokuskan untuk model dengan beberapa kata yang paling sering muncul dan relevan dalam data, sekaligus mengurangi kompleksitas akibat kata yang jarang digunakan. Selain itu, proses ini juga menggunakan mekanisme *out-of-vocabulary (OOV)* agar model tetap dapat memproses teks yang mengandung kata baru atau kata yang tidak dikenal [20].


Hasil dari proses tokenizing berupa urutan bilangan bulat, di mana setiap bilangan menunjukkan satu kata dalam teks. Panjang urutan token berbeda-beda untuk setiap kalimat menyesuaikan panjang teks. Oleh karena itu, perlu adanya proses padding yang berfungsi untuk menyamakan panjang input data. Pada penelitian ini, panjang maksimum urutan token ditetapkan sebesar 100 token. Teks yang memiliki panjang kurang dari tersebut akan ditambahkan nilai nol (*zero padding*), sedangkan teks yang melebihi batas akan dipotong.

```
array([[ 211,  353,  59, 1510, 483, 242,  2,  4,  3,  5],
       [ 84,  2, 977, 978, 77, 15, 77, 709, 979, 42],
       [ 980, 405, 27, 270, 1513, 1514, 1515, 354, 53, 406]],
      dtype=int32)
```

Gambar 7. Hasil Tokenizing & Padding

2) Split Data Train & Test

Pada tahap ini, dataset dipisahkan menjadi dua bagian, yaitu data latih (*train*) dan data uji (*test*), dengan perbandingan 80:20 dari total 966 data. Pembagian tersebut menghasilkan sekitar 700 data yang digunakan untuk proses pelatihan model dan sekitar 100 data untuk pengujian kinerjanya. Data latih digunakan untuk memungkinkan model mempelajari pola-pola yang terdapat dalam data, sementara data uji dimanfaatkan untuk menilai seberapa baik kemampuan model bekerja pada data yang baru atau data yang belum pernah dilihat sebelumnya. Dengan penerapan pembagian data tersebut, proses pelatihan dapat berlangsung secara optimal sehingga model yang dihasilkan memiliki kemampuan generalisasi yang baik.



Gambar 8. Split Data

E. Modeling LSTM

Arsitektur model LSTM yang diterapkan dalam penelitian ini menggunakan pendekatan *Sequential* yang terdiri dari beberapa lapisan utama, yaitu *input layer*, *embedding layer*, *LSTM*, *dropout*, dan *dense layer* [21]. Data input berupa urutan token sepanjang 100 kata yang diproses melalui *embedding layer* dengan dimensi vektor 128. Lapisan ini memiliki 1.024.000 parameter yang dilatih.

Selanjutnya, lapisan LSTM dengan 128-unit digunakan untuk melihat pola urutan dan konteks jangka panjang dalam data teks. Lapisan *dropout* dengan tingkat 0,3 juga diterapkan

untuk meminimalkan risiko *overfitting*. Sedangkan, lapisan *dense* menggunakan fungsi aktivasi *softmax* dengan tiga neuron digunakan untuk menghasilkan hasil klasifikasi sentimen ke dalam tiga kelas, yaitu kelas negatif, netral, dan positif.

Jika dilihat secara keseluruhan, model memiliki total 1.155.971 parameter yang seluruhnya bersifat *trainable*.

Model: "sequential"



Layer (type)	Output Shape	Param #
embedding (Embedding)	(None, 100, 128)	1,024,000
lstm (LSTM)	(None, 128)	131,584
dropout (Dropout)	(None, 128)	0
dense (Dense)	(None, 3)	387

Total params: 1,155,971 (4.41 MB)  
 Trainable params: 1,155,971 (4.41 MB)  
 Non-trainable params: 0 (0.00 B)

Gambar 9. Model Architecture

Model LSTM pada penelitian ini dilatih selama 8 epoch dengan *batch size* 32 dan *validation split* 10%. Selama tahapan pelatihan, nilai akurasi pada fase awal *epoch* mengalami peningkatan secara bertahap, dari 0,52 hingga mencapai 0,99 pada *epoch* terakhir. Hal ini juga disertai dengan penurunan nilai *loss* dari 1,01, menjadi 0,02. Hasil ini mengindikasikan bahwa model memiliki kemampuan yang baik dalam mempelajari pola sentimen yang ada dalam data.

Untuk data validasi, akurasi meningkat dari yang awalnya 0,57 menjadi sekitar 0,75, disertai dengan nilai *validation loss* yang cukup stabil. Perbedaan keduanya ini menunjukkan adanya kecenderungan *overfitting* dalam tingkat yang ringan, namun masih dalam batas stabil mengingat karakteristik data media sosial yang sangat kompleks dan bervariasi. Secara keseluruhan, hasil ini menunjukkan model LSTM mampu mempelajari data secara efektif dan layak untuk digunakan pada proses penelitian ini.



Gambar 10. Kinerja Pelatihan dan Validasi Model LSTM

F. Model Evaluation

Setelah membuat grafik *accuracy* dan *loss* menggunakan model LSTM, selanjutnya dilakukan evaluasi kinerja model menggunakan *classification report* yang mencakup metrik *accuracy*, *precision*, *recall*, dan *F1-score*.

TABEL IV  
METRIK EVALUASI PER LABEL SENTIMEN


Label	Precision	Recall	F1-Score	Support
Negative	0.85	0.81	0.83	118
Neutral	0.45	0.62	0.52	47
Positive	0.88	0.48	0.62	29
Accuracy			0.72	194
Macro avg	0.72	0.64	0.66	194
Weighted avg	0.76	0.72	0.72	194

Berdasarkan hasil pada data uji, model LSTM mencapai akurasi sebesar 0,72, yang menunjukkan bahwa model dapat mengklasifikasikan sentimen publik terhadap otomatisasi pekerjaan oleh AI dengan tingkat ketepatan yang cukup baik.

Pada kelas sentimen negatif, model menunjukkan kinerja paling optimal dengan nilai *precision* sebesar 0,85, *recall* sebesar 0,81, dan *F1-score* sebesar 0,83. Tingginya nilai *recall* pada kelas negatif menunjukkan model memiliki kemampuan yang baik dalam mengidentifikasi komentar yang mengandung sentimen negatif, seperti kekhawatiran terhadap penggantian pekerjaan oleh AI.

Pada kelas sentimen netral, nilai *precision* sebesar 0,45, *recall* 0,62, dan *F1-score* 0,52. Nilai ini menunjukkan sentimen netral relatif lebih sulit diklasifikasikan secara konsisten. Hal ini bisa disebabkan oleh karakteristik teks yang ambigu.

Untuk sentimen positif didapatkan *precision* yang cukup tinggi sebesar 0,88, namun dengan *recall* rendah yaitu 0,48, yang menunjukkan prediksi positif cenderung tepat, meskipun masih terdapat beberapa data positif yang terklasifikasi ke kelas lain.



Gambar 11. Normalized Confusion Matrix Model LSTM

Normalized confusion matrix digunakan untuk mengevaluasi pola kesalahan klasifikasi yang dihasilkan oleh model LSTM pada tiga kategori sentimen, yaitu negatif, netral, dan positif. Normalisasi dilakukan untuk menampilkan proporsi prediksi pada setiap kelas untuk memudahkan interpretasi kinerja model secara komparatif.

Dalam confusion matrix tersebut, kelas sentimen negatif menunjukkan tingkat klasifikasi benar sebesar 0,83. Hal ini menunjukkan bahwa mayoritas data yang benar bersentimen negatif berhasil diprediksi dengan tepat sebagai negatif.

Pada kelas sentimen netral, klasifikasi benar berada pada nilai 0,53, sementara kesalahan klasifikasi paling dominan terjadi ketika data netral diprediksi sebagai negatif dengan nilai 0,36. Pola ini menunjukkan bahwa terdapat data netral yang memiliki kemiripan dengan sentimen negatif yang dapat disebabkan oleh data media sosial yang mengandung kata-kata ambigu.

Pada kelas sentimen positif, menunjukkan tingkat klasifikasi benar sebesar 0,66, dengan kesalahan terjadi ketika data positif diprediksi sebagai negatif sebesar 0,34. Tidak ada kesalahan klasifikasi data positif ke kelas negatif, yang menunjukkan model hanya memberikan label negatif ketika terdapat indikator sentimen negatif yang cukup kuat.

Secara keseluruhan, confusion matrix menunjukkan model LSTM lebih andal dalam mendeteksi sentimen negative dan dengan performa terbaik pada kelas negatif, model ini dinilai efektif untuk tujuan utama penelitian, yaitu untuk menganalisis persepsi risiko *job displacement* akibat otomatisasi pekerjaan oleh AI.

Meskipun model LSTM menunjukkan kinerja yang cukup baik dalam mengklasifikasikan sentimen publik, keterbatasan pada jumlah dataset yang digunakan, yaitu sebanyak 966 tweet berpotensi memengaruhi kemampuan generalisasi model ketika diterapkan pada data dengan karakteristik yang berbeda. Maka, untuk meminimalkan risiko overfitting, penelitian ini telah menerapkan teknik regularisasi seperti penggunaan dropout dan validation split selama proses pelatihan.

Selain itu, sumber data yang berasal dari media sosial Twitter/X juga memiliki keterbatasan dalam hal representativitas. Pengguna media sosial tidak sepenuhnya merepresentasikan seluruh populasi masyarakat Indonesia, baik dari segi demografis maupun tingkat literasi digital. Oleh karena itu, hasil model LSTM ini lebih mencerminkan persepsi pengguna aktif media sosial dan tidak dapat digeneralisasikan secara langsung ke seluruh masyarakat.

Untuk mengevaluasi keunggulan model LSTM, dilakukan juga perbandingan dengan model baseline berbasis TF-IDF, yaitu Logistic Regression dan Linear Support Vector Machine (SVM). Hasil evaluasi menunjukkan bahwa Logistic Regression memperoleh akurasi sebesar 69,6% dengan weighted F1-score sebesar 0,64, sedangkan LinearSVM mencapai akurasi sebesar 74,2% dengan weighted F1-score sebesar 0,71. Model LSTM dalam penelitian ini menghasilkan akurasi sebesar 72% dengan weighted F1-score sebesar 0,72. Meskipun Linear SVM menunjukkan akurasi yang sedikit lebih tinggi, LSTM memberikan performa yang sebanding dengan keunggulan dalam menangkap dependensi sekuensial antar kata dalam teks. Hal ini menjadi pertimbangan penting dalam analisis sentimen berbasis konteks, terutama untuk memahami konteks bahasa dalam percakapan di media sosial.

```

=== Logistic Regression (TF-IDF) ===
Accuracy: 0.6959
Weighted F1: 0.6373

```

	precision	recall	f1-score	support
negative	0.73	1.00	0.85	118
neutral	0.42	0.23	0.30	47
positive	0.86	0.21	0.33	29
accuracy			0.70	194
macro avg	0.67	0.48	0.49	194
weighted avg	0.68	0.70	0.64	194

```

=== SVM LinearSVC (TF-IDF) ===
Accuracy: 0.7423
Weighted F1: 0.7132

```

	precision	recall	f1-score	support
negative	0.80	0.97	0.88	118
neutral	0.48	0.30	0.37	47
positive	0.68	0.52	0.59	29
accuracy			0.74	194
macro avg	0.66	0.60	0.61	194
weighted avg	0.71	0.74	0.71	194

Gambar 12. Performa Logistic Regression dan SVM sebagai Pembanding

### G. Modeling BERTopic

Setelah proses pemodelan LSTM selesai, tahap berikutnya adalah pemodelan menggunakan BERTopic yang bertujuan untuk mengidentifikasi isu-isu utama yang membentuk sentimen publik terhadap otomatisasi pekerjaan oleh AI. Namun, analisis hanya difokuskan pada kalimat dengan sentimen negatif dan netral, dengan total 822 data yang digunakan. Representasi teks dibangun dengan model

embedding *SentenceTransformer all-MiniLM-L6-v2* yang kemudian dikelompokkan berdasarkan kemiripan.

```
embedding_model = SentenceTransformer("all-MiniLM-L6-v2")

topic_model = BERTopic(
    embedding_model=embedding_model,
    language="indonesian",
    min_topic_size=15,
    calculate_probabilities=True,
    verbose=True
)

topics, probs = topic_model.fit_transform(texts)


topic_info = topic_model.get_topic_info()
topic_info.head(10)
```

Topic	Count	Name	Representation	Representative_Docs
-1	234	-1_kerja_ganti_orang_teknologi	[kerja, ganti, orang, teknologi, phk, hilang, ...]	[etika cerdas buat hidup sehari-hari bias ai se...
0	117	0_manusia_ganti_kerja_sulit	[manusia, ganti, kerja, sulit, manusiawi, lu, ...]	[ai manusia, ai ganti kerja manusia, ai ganti ...]
1	91	1_ganti_kerja_takut_jurus	[ganti, kerja, takut, jurus, gambar, voice, ba...]	[ai ganti kerja ai, kerja ganti ai, kerja gant...]
2	86	2_robot_kerja_manusia_ganti	[robot, kerja, manusia, ganti, humanoid, robot...]	[robot ai ubah kerja video robot amazon ada ke...]
3	35	3_seniman_hilang_pakai_kerja	[seniman, hilang, pakai, kerja, bikin, chalgpt...]	[btw tulis orang hilang empati seniman so kalo...]
4	28	4_tugas_teliti_manusia_ambil	[tugas, teliti, manusia, ambil, alih, kerja, o...]	[ai dampak kerja otomatisasi tugas rutin poten...]
5	27	5_programmer_ganti_developer_software	[programmer, ganti, developer, software, engin...]	[isu ai ganti programmer fakta fiksi khawatir ...]
6	25	6_skill_kalo_anak_ganti	[skill, kalo, anak, ganti, our, dr, kerja, ban...]	[ai tools bantu kerja seniman nggak ganti fung...]
7	23	7_data_cipta_dampak_analis	[data, cipta, dampak, analis, pariwisata, khaw...]	[erti khawatir dampak ai indonesia lantang lap...]
8	22	8_artificial_intelligence_learning_machine	[artificial, intelligence, learning, machine, ...]	[ai ubah hidup ganti kerja tingkat inovasi art...]

Gambar 13. Proses dan Hasil Pemodelan Topik Menggunakan BERTopic

Hasil pemodelan menunjukkan bahwa topik dominan berkaitan dengan kekhawatiran AI dan teknologi dalam menggantikan pekerjaan manusia, yang diperkuat oleh kata kunci seperti kerja, ganti, orang, teknologi, phk, dan hilang. Selain itu, muncul topik kerentanan pada profesi tertentu, seperti programmer, developer, dan pekerja di sektor kreatif seperti seniman, serta topik mengenai peran robot dalam menggantikan pekerjaan manusia. Di sisi lain, beberapa topik menunjukkan pembahasan mengenai tugas, keterampilan, serta perkembangan artificial intelligence dan machine learning, yang mengindikasikan adanya kesadaran publik terhadap perlunya adaptasi dan penyesuaian kompetensi di era transformasi digital.

Selanjutnya, untuk memperjelas representasi kata kunci dominan pada topik-topik utama tersebut, dilakukan juga visualisasi dalam bentuk bar chart sebagaimana ditunjukkan pada Gambar 14.



Gambar 14. Visualisasi Hasil Pemodelan Topik dalam Bentuk Bar Chart

Visualisasi pada Gambar 14 menampilkan distribusi kata kunci dominan dari tiga topik dengan jumlah dokumen terbesar. Topic 0 didominasi oleh kata *kerja*, *ganti*, *manusia*, dan *teknologi*, yang merefleksikan kekhawatiran publik terhadap potensi penggantian tenaga kerja oleh AI. Topic 1 menyoroti diskursus mengenai robot dan otomatisasi fisik dalam dunia kerja, sedangkan Topic 2 menggambarkan pembahasan yang lebih teknis terkait *artificial intelligence* dan *machine learning*. Secara keseluruhan, hasil ini menunjukkan bahwa perspektif publik tidak hanya berfokus pada ancaman kehilangan pekerjaan, tetapi juga pada transformasi teknologi dan kebutuhan adaptasi keterampilan.

Secara keseluruhan, hasil BERTopic memperkuat temuan analisis sentimen bahwa publik di Indonesia saat ini didominasi isu risiko *job displacement*.

H. Time-Series Analysis & Forecasting (ARIMA)

Analisis deret waktu dilakukan juga dilakukan untuk memahami dinamika perubahan sentimen publik terhadap risiko *job displacement* akibat otomatisasi pekerjaan oleh AI dari waktu ke waktu, serta memproyeksikan kecenderungan sentimen tersebut pada periode mendatang. Data yang digunakan menggunakan diambil dari skor sentimen hasil klasifikasi LSTM yang telah diagregasi secara bulanan berdasarkan waktu unggah tweet dengan cara menghitung nilai rata-rata skor sentimen setiap bulannya. Hingga akhirnya diperoleh satu deret waktu yang merepresentasikan sentimen publik secara temporal.

Dalam pemodelan ini, digunakan *Augmented Dickey-Fuller (ADF)* menghasilkan *p-value* sebesar 0,0026 (< 0,05), yang menunjukkan bahwa deret waktu bersifat stasioner dan memenuhi standar pemodelan ARIMA. Model ARIMA (1,1,1) diterapkan untuk menganalisis komponen autoregresif, diferensiasi, dan *moving average* secara seimbang [22]. Hasilnya menunjukkan komponen *moving average* cukup berpengaruh terhadap pola perubahan sentimen, sedangkan komponen autoregresif berkontribusi dalam menjaga kesinambungan nilai sentimen antar periode. Nilai *Akaike Information Criterion (AIC)* dan *Bayesian Information Criterion (BIC)* cenderung relatif rendah. Hal ini mengindikasikan model memiliki tingkat kecocokan yang memadai terhadap data historis.

SARIMAX Results

---

Dep. Variable:	sentiment_score	No. Observations:	24
Model:	ARIMA(1, 1, 1)	Log Likelihood	12.622
Date:	Mon, 15 Dec 2025	AIC	-19.243
Time:	08:56:54	BIC	-15.837
Sample:	01-31-2024	HQIC	-18.387
	- 12-31-2025		

---

Covariance Type: opg

	coef	std err	z	P> z	[0.025	0.975]
ar.L1	0.1838	0.303	0.607	0.544	-0.410	0.778
ma.L1	-0.9354	0.244	-3.841	0.000	-1.413	-0.458
sigma2	0.0181	0.005	3.909	0.000	0.009	0.027

---


Ljung-Box (L1) (Q):	0.10	Jarque-Bera (JB):	0.91
Prob(Q):	0.76	Prob(JB):	0.63
Heteroskedasticity (H):	0.93	Skew:	-0.30
Prob(H) (two-sided):	0.92	Kurtosis:	3.77

---

Gambar 15. Hasil Estimasi Model ARIMA (1,1,1)

Untuk mengevaluasi performa model ARIMA, dilakukan pembagian data menjadi data pelatihan dan pengujian dengan proporsi 75%–25%. Hasil evaluasi menunjukkan nilai Mean Absolute Error (MAE) sebesar 0,093 dan Root Mean Squared Error (RMSE) sebesar 0,132. Nilai error yang relatif kecil dibandingkan rentang skor sentimen menunjukkan bahwa model ARIMA mampu merepresentasikan pola temporal sentimen publik dengan tingkat akurasi yang memadai. Dengan demikian, model dinilai cukup stabil dalam melakukan peramalan jangka pendek terhadap tren sentimen risiko *job displacement* akibat AI.

Setelah model selesai dibuat, dilakukan peramalan sentimen dengan periode enam bulan ke depan. Hasil *forecasting* menunjukkan bahwa nilai rata-rata skor sentimen tetap berada pada rentang negatif dan cenderung stabil tanpa fluktuasi yang ekstrem. Kondisi ini menunjukkan bahwa sentimen negative masih mendominasi persepsi publik dan berpotensi akan bertahan dalam jangka pendek. Tidak adanya tren kenaikan yang signifikan pada skor sentimen menunjukkan publik masih khawatir terhadap risiko penggantian pekerjaan oleh AI.



Gambar 16. Hasil Forecast Tren Sentimen Publik

Dari periode yang telah ada sesuai dengan dataset hingga periode prediksi yang akan datang, visualisasi antara data historis dan *forecast* memperlihatkan kesamaan pola sentimen negatif. Hal ini memperkuat adanya isu otomatisasi

pekerjaan oleh AI yang masih dipersepsikan sebagai ancaman oleh sebagian besar masyarakat. Dengan demikian, hasil analisis ini memberikan bukti bahwa risiko *job displacement* akibat AI berpotensi menjadi perhatian publik yang berkelanjutan.

Hasil sentimen publik kemungkinan juga berkaitan dengan perkembangan kebijakan dan berita teknologi global. Dalam beberapa tahun terakhir, kebijakan pemerintah Indonesia yang mendorong transformasi digital serta pemberitaan mengenai kemajuan AI generatif, otomatisasi industri, serta diskursus global terkait pengurangan tenaga kerja akibat adopsi teknologi AI berpotensi memengaruhi persepsi publik.

Dari hasil *forecast* juga menunjukkan bahwa kekhawatiran publik bukanlah fenomena sementara, melainkan refleksi dari persepsi risiko yang relatif stabil. Kondisi ini memiliki implikasi penting terhadap perumusan kebijakan ketenagakerjaan dan strategi pengembangan sumber daya manusia di era transformasi digital.

Secara kebijakan, hasil ini mengindikasikan perlunya program pelatihan ulang (*reskilling*) dan peningkatan keterampilan (*upskilling*) yang lebih terarah, khususnya bagi sektor pekerjaan yang rentan terhadap otomatisasi, seperti pekerjaan administratif, industri manufaktur, dan layanan berbasis rutinitas. Selain itu, penguatan literasi digital dan pemahaman dasar mengenai kecerdasan buatan menjadi krusial agar tenaga kerja mampu beradaptasi dengan perubahan teknologi. Dengan demikian, temuan penelitian ini dapat menjadi dasar dalam merancang kebijakan transisi tenaga kerja yang lebih inklusif dan berkelanjutan di tengah percepatan adopsi teknologi berbasis AI.

#### IV. KESIMPULAN

Hasil analisis menunjukkan bahwa sentimen publik didominasi oleh sentimen negatif, yang mencerminkan tingginya kekhawatiran masyarakat terhadap risiko *job displacement* akibat AI.

Hasil analisis menunjukkan model LSTM mencapai tingkat akurasi tertinggi sebesar 72% serta memiliki kinerja yang lebih baik dalam mengidentifikasi sentimen negatif jika dibandingkan sentimen netral dan positif. Pemodelan topik menggunakan BERTopic berhasil mengungkap isu-isu utama yang membentuk persepsi publik, seperti kekhawatiran terhadap penggantian pekerjaan oleh AI, ancaman terhadap profesi tertentu, serta kebutuhan adaptasi keterampilan di era digital.

Analisis *time series forecasting* menunjukkan rata-rata skor sentimen publik cenderung berada pada nilai negatif secara konsisten dan hasil *forecasting* menggunakan model ARIMA mengindikasikan bahwa sentimen negatif terkait risiko *job displacement* akan berpotensi berlanjut pada periode mendatang. Secara keseluruhan, penelitian ini membuktikan bahwa antara analisis sentimen, pemodelan topik, dan analisis *time series forecasting* efektif dalam memahami persepsi risiko publik terhadap otomatisasi pekerjaan oleh AI di Indonesia.

## DAFTAR PUSTAKA

- [1] Izzatul Mula and Auliya Ristiani, "Transformasi Struktur Pekerjaan dan Kebutuhan Keterampilan di Era Teknologi AI dan Otomatisasi di Pasar Global," *Nian Tana Sikka: Jurnal ilmiah Mahasiswa*, vol. 3, no. 1, pp. 155–167, Jan. 2025, doi: 10.59603/niantanasikka.v3i1.665.
- [2] R. Putra, Sularno, and Zulfahmi, "Analisis Dampak Kecerdasan Buatan terhadap Transformasi Lapangan Kerja: Studi Literatur Sistematis," *JISKA: Jurnal Sistem Informasi dan Informatika*, vol. 3, no. 2, pp. 70–74, Jul. 2025. [Online]. Available: <http://jurnal.unidha.ac.id/index.php/jiska>
- [3] L. O. Lukmana, "Analisis Sentimen Terhadap Ulasan Pengguna Aplikasi Threads Instagram di Playstore Menggunakan Algoritma Naive Bayes," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 13, no. 2, Apr. 2025, doi: 10.23960/jitet.v13i2.6250.
- [4] A. C. N. Rosyadi, Muhammad Athoillah, and Fenny Fitriani, "Analisis Sentimen Pengguna Twitter Mengenai Kotak Kosong di Pilkada Indonesia Tahun 2024 Menggunakan Algoritma LSTM," *Komputika : Jurnal Sistem Komputer*, vol. 14, no. 2, pp. 193–202, Nov. 2025, doi: 10.34010/komputika.v14i2.16976.
- [5] I. K. T. Mertayasa and I. D. M. B. A. Darmawan, "Pemodelan Topik Pada Ulasan Hotel Menggunakan Metode BERTopic Dengan Prosedur c-TF-IDF," *Jurnal Nasional Teknologi Informasi dan Aplikasinya (JNATIA)*, vol. 1, no. 1, pp. 307–316, Nov. 2022.
- [6] D. Ayu Rezaldi, "PRISMA, Prosiding Seminar Nasional Matematika Peramalan Metode ARIMA Data Saham PT. Telekomunikasi Indonesia," *Peramalan Metode ARIMA Data Saham PT. Telekomunikasi Indonesia. PRISMA, Prosiding Seminar Nasional Matematika*, vol. 4, pp. 611–620, 2021, [Online]. Available: <https://journal.unnes.ac.id/sju/index.php/prisma/>
- [7] P. Rahmadani Panggabean and H. Al-Kausar Aidilof, "Sentiment Analysis of Public Comments on X Social Media Related to Israeli Product Boycotts Using The Long Short-Term Memory (LSTM) Method," 2025. [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>
- [8] A. Rizky Gunawan, R. Faticha, and A. Aziza, "Sentiment Analysis Using LSTM Algorithm Regarding Grab Application Services in Indonesia," 2025. [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>
- [9] I. Amelia *et al.*, "Analisis Sentimen Opini Publik Terhadap Pengambil Alihan TMII Oleh Pemerintah dengan Algoritma Naive Bayes." [Online]. Available: <https://journals.upi-yai.ac.id/index.php/ikraith-informatika/issue/archive>
- [10] M. U. Albab, Y. K. P., and M. N. Fawaiq, "Optimization of the Stemming Technique on Text Preprocessing President 3 Periods Topic," *Jurnal Transformatika*, vol. 20, no. 2, pp. 1–12, Jan. 2023, doi: 10.26623/transformatika.v20i2.5374.
- [11] S. Jessica Angelina, A. Bijaksana Putra Negara, H. Muhandi, J. H. Nawawi, and K. Barat, "Analisis Pengaruh Penerapan Stopword Removal Pada Performa Klasifikasi Sentimen Tweet Bahasa Indonesia Analyzing The Impact Of Applying Stopword Removal On Indonesian Tweet Sentiment Classification," vol. 02, no. 1, 2023, doi: 10.26418/juara.v2i1.69680.
- [12] A. S. Paramita and J. Jusak, "Fine-Grained Sentiment Analysis Approach on Customer Reviews Based on Aspect-Level Emotion Detection," *Journal of Applied Data Sciences*, vol. 6, no. 3, pp. 2235–2247, Jul. 2025, doi: 10.47738/jads.v6i3.964.
- [13] R. Wajhillah and A. Wibowo, "Information Retrieval Pemetaan Peta Jalan Penelitian Perguruan Tinggi Berbasis Dokumen Publikasi Ilmiah Dosen," 2021. [Online]. Available: <http://jurnal.bsi.ac.id/index.php/larik>
- [14] K. S. Witanto, N. A. Sanjaya ER, A. A. I. N. Eka Karyawati, I. G. A. G. A. Kadyanan, I. K. G. Suhartana, and L. G. Astuti, "Implementasi LSTM pada Analisis Sentimen Review Film Menggunakan Adam dan RMSprop Optimizer," *Jurnal Elektronik Ilmu Komputer Udayana*, vol. 10, no. 4, pp. 351–362, May 2022.
- [15] J. Cahyani, S. Mujahidin, and T. P. Fiqar, "Implementasi Metode Long Short Term Memory (LSTM) untuk Memprediksi Harga Bahan Pokok Nasional," *Jurnal Sistem dan Teknologi Informasi (JustIN)*, vol. 11, no. 2, p. 346, Jul. 2023, doi: 10.26418/justin.v11i2.57395.
- [16] W. Wahyuni, T. P. Lestari, M. Apriliana, and R. Gumelta, "Implementation of BERTopic for Topic Modeling Analysis of the Free Nutritious Meal Program Based on YouTube Comments," 2025. [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>
- [17] S. V. Kedar and S. Kadam, "Stock Market Increase and Decrease using Twitter Sentiment Analysis and ARIMA Model," 2021.
- [18] Y. Saputri, F. Syaki, and N. Hadinata, "Sentiment Analysis of Trending Topics on Social Media X Using Natural Language Processing and LSTM," 2025. [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>
- [19] A. Rachmadana Ismail, R. Bagus, F. Hakim, and R. Artikel, "Implementasi Lexicon Based Untuk Analisis Sentimen Dalam Mengetahui Trend Wisata Pantai Di DI Yogyakarta Berdasarkan Data Twitter P-ISSN E-ISSN," 2023.
- [20] H. Meliana Pratama, I. Lanang Wijayakusuma, and R. S. Widiastuti, "Comparison of Online Gambling Promotion Detection Performance Using DistilBERT and DeBERTa Models," 2025. [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>
- [21] C. K. N. Papatungan and A. Jacobus, "Sentiment Analysis of Social Media Users Using Long-Short Term Memory Method Analisis Sentimen Pengguna Sosial Media Menggunakan Metode Long Short Term Memory," *Jurnal Teknik Elektro dan Komputer*, vol. 10, no. 2.
- [22] M. M. Gazali and H. Setiawan, "Penerapan Model ARIMA untuk Meramalkan Harga Pembukaan Harian Saham PT. Bank Central Asia Tbk," *Digital Transformation Technology*, vol. 5, no. 1, pp. 278–289, Jul. 2025, doi: 10.47709/digitech.v5i1.6129.