

Analisis Sentimen berbasis Deep Learning Terhadap Kesetaraan Gender di Bidang STEM: Perspektif dan Implikasinya

Siti Mariam^{1,*}, Ida Nurhaida^{1,2}

¹ Program Studi Informatika, Universitas Pembangunan Jaya, Indonesia

² Center of Urban Studies, Universitas Pembangunan Jaya, Indonesia

* Correspondence: siti.mariam@student.upj.ac.id

Copyright: © 2025 by the authors

Received: 27 Desember 2024 | Revised: 1 Januari 2025 | Accepted: 31 Januari 2025 | Published: 11 April 2025

Abstrak

Partisipasi perempuan di bidang Sains, Teknologi, Teknik, dan Matematika (STEM) masih rendah akibat diskriminasi, stereotip *gender*, dan kurangnya akses terhadap peluang karier yang setara. Penelitian ini menganalisis sentimen masyarakat tentang kesetaraan *gender* di bidang STEM menggunakan pendekatan *Knowledge Discovery in Database* (KDD) dengan algoritma *Long Short-Term Memory* (LSTM). Data terdiri dari 1.200 *tweet* (2018–2024) yang dikumpulkan melalui *web crawling* dan diproses menggunakan teknik KDD seperti *preprocessing*, *transformation*, *data mining* dan *evaluation*. Model LSTM yang dihasilkan menunjukkan akurasi 86,25%, presisi 88,18%, *recall* 82,20%, dan *F1-score* 85,00%. Analisis sentimen menunjukkan dukungan dan apresiasi terhadap perempuan di STEM (sentimen positif) serta kritik terhadap diskriminasi dan stereotip *gender* (sentimen negatif). Penelitian ini menghadapi tantangan berupa ketidakseimbangan data dan kesulitan model dalam memahami konteks bahasa Indonesia. Temuan kami menegaskan pentingnya kebijakan yang mendukung kesetaraan *gender* dan lingkungan kerja yang inklusif. Penelitian ini diharapkan dapat memperbaiki persepsi masyarakat terhadap kesetaraan *gender* dan meningkatkan representasi perempuan di bidang STEM, terutama di Indonesia.

Kata kunci: analisis sentimen; *deep learning*; kesetaraan *gender*; media sosial; stem

Abstract

Women's participation in Science, Technology, Engineering, and Mathematics (STEM) is still low due to discrimination, gender stereotypes, and lack of access to equal career opportunities. This research analyzes public sentiment about gender equality in STEM fields using the Knowledge Discovery in Database (KDD) approach with the Long Short-Term Memory (LSTM) algorithm. The data consists of 1,200 tweets (2018-2024) collected through web crawling and processed using KDD techniques such as preprocessing, transformation, data mining and evaluation. The resulting LSTM model showed 86.25% accuracy, 88.18% precision, 82.20% recall, and 85.00% F1-score. Sentiment analysis showed support and appreciation for women in STEM (positive sentiment) and criticism of gender discrimination and stereotypes (negative sentiment). This study faced challenges in the form of data imbalance and the model's difficulty in understanding the Indonesian context. Our findings confirm the importance of policies that support gender equality and inclusive work environments. This research is expected to improve people's perception of gender equality and increase the representation of women in STEM fields, especially in Indonesia.

Keywords: *sentiment analysis; deep learning; gender equality; social media; stem*

PENDAHULUAN

Kesetaraan *gender* merupakan isu krusial dalam diskursus global terkait keadilan sosial dan hak asasi manusia (Pane et al., 2024). Di era modern yang ditandai oleh kemajuan ilmu



pengetahuan dan teknologi, tantangan disparitas *gender* di bidang STEM tetap menjadi perhatian utama karena dampaknya yang luas, baik secara sosial maupun ekonomi (Rini et al., 2022). *Gender* yang mencakup peran dan tanggung jawab sosial laki-laki dan perempuan, terus berkembang dengan dukungan masyarakat dalam konteks sosial dan budaya tertentu (Yazidi et al., 2023).

Sebagai bagian dari upaya mencapai tujuan Pembangunan Berkelanjutan (SDGs), khususnya tujuan ke-5, peningkatan representasi perempuan di STEM menjadi prioritas utama untuk memastikan akses yang setara dalam pendidikan dan karier (Sudirman et al., 2022). Meski demikian, data menunjukkan partisipasi perempuan di STEM masih rendah. Hanya 30% peneliti dunia adalah perempuan, sementara di Indonesia, hanya 28% pekerja di sektor teknologi informasi merupakan perempuan (Amriyati et al., 2023). Rendahnya representasi ini dipengaruhi oleh stereotip *gender*, kurangnya figur teladan, dan kebijakan yang masih belum mendukung (Meoli, 2024). Rendahnya representasi perempuan di STEM menunjukkan adanya kesenjangan yang signifikan antara kebutuhan dan realitas di lapangan (Fouad et al., 2023). Sebagian besar penelitian sebelumnya cenderung deskriptif dan belum memanfaatkan teknologi modern untuk mengeksplorasi sentimen masyarakat secara mendalam, khususnya di Indonesia.

Sebagai salah satu cabang dari kecerdasan buatan, algoritma *Long Short-Term Memory* (LSTM) memiliki potensi besar untuk mendukung analisis data sekuensial, termasuk analisis sentimen teks. LSTM adalah jenis jaringan saraf tiruan yang dirancang untuk memahami pola dalam data sekuensial, dengan arsitektur unik yang memungkinkan model mempertahankan informasi dari langkah sebelumnya dalam urutan data (Hasiholan et al., 2022). Keunggulan ini membuat LSTM efektif dalam menangkap konteks jangka panjang dan memberikan analisis mendalam terhadap pola data yang dinamis (Yuniarossy et al., 2024). *Deep learning* termasuk LSTM, dirancang untuk memproses data kompleks, seperti teks, gambar, dan suara (Sedana et al., 2024). Dalam konteks analisis sentimen, LSTM menunjukkan keunggulan signifikan dibandingkan algoritma tradisional.

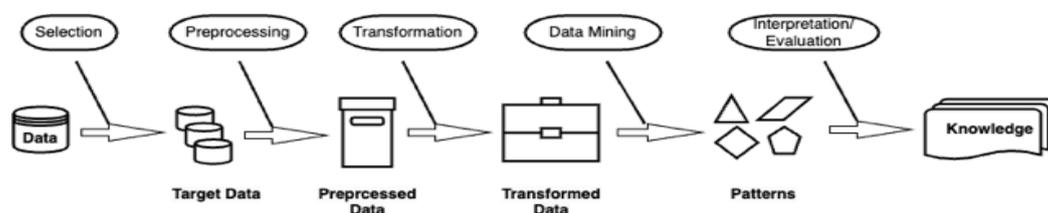
Penelitian ini memilih untuk menggunakan pendekatan berbasis data kuantitatif dengan analisis sentimen sebagai upaya mengeksplorasi kesenjangan representasi perempuan di STEM. Dalam konteks ini, LSTM dianggap sebagai solusi yang unggul dibandingkan algoritma lainnya, seperti *naïve bayes* yang lebih terbatas pada dataset kecil (Rumaisa et al., 2021). Selain itu, hasil penelitian Wahyuni (2022) menunjukkan bahwa penggunaan LSTM secara signifikan dapat meningkatkan akurasi dalam analisis sentimen, terutama pada dataset yang besar dan kompleks (Arsi et al., 2021). Hal ini menjadikan LSTM sebagai metode yang lebih andal untuk memahami data teks yang dinamis dan beragam (Isnain et al., 2022). Dalam pengaplikasiannya, LSTM menawarkan pendekatan yang lebih adaptif dan mendalam dalam mengolah data teks dibandingkan algoritma lainnya (Zharifa et al., 2024).

Meskipun berbagai studi telah mengkaji persepsi publik terhadap kesetaraan *gender* di bidang STEM, sebagian besar penelitian terdahulu masih terbatas pada analisis yang bersifat umum dan kurang mendalam mengenai sentimen masyarakat, khususnya di Indonesia. Sebagian besar kajian sebelumnya mengandalkan pendekatan kualitatif atau analisis data yang terbatas, sedangkan penggunaan data *real-time* dari *platform* media sosial seperti *twitter* dalam konteks ini masih belum banyak dieksplorasi (Lidinillah et al., 2023). Selain itu, meskipun ada sejumlah penelitian mengenai kesetaraan *gender* (Syah et al., 2023), penerapan teknik analisis sentimen berbasis algoritma canggih, seperti LSTM, dalam menganalisis data dari media sosial masih jarang ditemui (Cahyadi et al., 2020). Hal ini menyebabkan terbatasnya pemahaman tentang dinamika opini publik yang lebih mendalam terkait isu ini (Azrul et al., 2024). Dengan demikian, terdapat kebutuhan mendesak untuk mengembangkan pendekatan yang lebih komprehensif dalam memahami opini publik secara mendalam.

Penelitian ini bertujuan untuk mengembangkan pendekatan berbasis *deep learning* dalam memahami sentimen masyarakat terhadap kesetaraan *gender* di bidang STEM. Dengan memanfaatkan data *real-time* dari *Twitter*, penelitian ini diharapkan dapat menggali perspektif masyarakat Indonesia secara lebih mendalam dan mencerminkan beragam pandangan terkait isu kesetaraan *gender*. Pendekatan berbasis LSTM akan digunakan untuk menganalisis sentimen, yang dapat memberikan wawasan lebih komprehensif dan mendalam dibandingkan metode tradisional. Selain itu, penelitian ini bertujuan untuk mengisi kekosongan dalam literatur dengan memberikan implikasi terhadap perumusan kebijakan yang lebih inklusif, guna mendukung peningkatan representasi perempuan di bidang STEM. Dengan demikian, penelitian ini diharapkan dapat berkontribusi pada pemahaman yang lebih baik tentang opini publik dan memandu langkah-langkah strategis untuk menciptakan kesetaraan *gender* di sektor STEM.

METODE

Penelitian ini menggunakan pendekatan *Knowledge Discovery in Database* (KDD) untuk mendeteksi ujaran kebencian (Naufal, 2022) dengan menganalisis data terkini. Proses KDD mencakup berbagai tahapan, mulai dari seleksi data, preprocessing, transformasi, hingga ekstraksi informasi yang signifikan. Dalam hal ini, data *tweet* tentang "kesetaraan *gender*" dan "STEM" dari 2018 hingga 2024 dikumpulkan dengan menggunakan *Tweet Harvest*, menghasilkan 1200 *tweet* yang dibagi menjadi 80% data latih dan 20% data uji. Data ini dilabeli secara manual, dengan sentimen negatif diberi label 0 dan positif diberi gambar 1.



Gambar 1. Metode pendekatan kdd

Proses *preprocessing* mencakup normalisasi kata, penghapusan tanda baca, *case folding*, *stopword removal*, dan *stemming* (menggunakan *porter stemmer*). Pada tahap transformasi, teks diubah menjadi representasi numerik melalui tokenisasi dan *padding*. Tokenisasi memecah teks menjadi token dengan indeks unik, sementara *padding* menambah nol pada teks yang lebih pendek agar urutannya konsisten. Representasi numerik ini digunakan sebagai input untuk *embedding layer*, yang mengubah token menjadi vektor berdimensi tetap untuk menangkap konteks semantik.

Pada tahap *data mining*, *embedding layer* digunakan untuk memetakan kata-kata menjadi vektor numerik, memungkinkan pemahaman kontekstual. LSTM layer yang terdiri dari 100-unit menangkap pola sekuensial dalam data teks, sementara *dense layer* dengan fungsi aktivasi *sigmoid* melakukan klasifikasi biner. Untuk mencegah *overfitting*, diterapkan *dropout* sebesar 0,2 dan *early stopping* berdasarkan performa data validasi. Fungsi *loss* yang digunakan adalah *binary cross-entropy*, dan *class weights* dihitung untuk mengatasi ketidakseimbangan data, memastikan model tidak hanya mengandalkan kelas dominan. Perhitungan *class weights* dijelaskan lebih lanjut pada persamaan 1. Sedangkan, perhitungan LSTM layer dapat dilihat pada persamaan 2.

$$w_c = \frac{n}{k \cdot n_c} \quad (1)$$

Keterangan:

w_c = Bobot kelas,

n = Jumlah total data

k = Jumlah kelas

n_c = Jumlah data dalam kelas

$$\text{Parameter LSTM} = (4 \times \text{Unit} \times (\text{Input Size} + \text{Unit})) + \text{Bias} \quad (2)$$

$$\text{Akurasi} = \text{TP} + \text{TN} \quad (3)$$

$$\text{Presisi} = \text{TP} / (\text{TP} + \text{FP}) \quad (4)$$

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN}) \quad (5)$$

$$\text{F1-Score} = \text{F1-Score} = \frac{2 \times (\text{Precision} \times \text{Recall})}{\text{Precision} + \text{Recall}} \quad (6)$$

Keterangan:

True Positives (TP)

True Negatives (TN)

False Positives (FP)

False Negatives (FN)

False Positive Rate (FPR)

False Negative Rate (FNR)

Perhitungan parameter pada model LSTM bergantung pada jumlah unit dalam setiap layer, ukuran input, dan bias. Model ini memiliki empat gerbang utama yang mengatur aliran informasi, dengan evaluasi kinerja yang dilakukan menggunakan metrik akurasi, presisi, *recall*, dan *F1-score*, sebagaimana ditunjukkan dalam Persamaan (3), (4), (5), dan (6). Presisi menunjukkan seberapa akurat prediksi positif yang dibuat model, sedangkan *recall* mengukur seberapa banyak data positif yang berhasil terdeteksi. *F1-score* digunakan untuk menyeimbangkan presisi dan *recall* agar memberikan gambaran performa model yang lebih baik, terutama jika terdapat ketidakseimbangan data.

Pada tahap evaluasi, performa model diukur menggunakan akurasi, presisi, *recall*, dan *F1-score*. Hasil evaluasi diperoleh melalui kurva *loss*, akurasi, dan *confusion matrix*. Selain itu, analisis visual seperti *word cloud* digunakan untuk mengidentifikasi kata-kata yang sering muncul, memberikan wawasan tentang sentimen masyarakat terhadap kesetaraan *gender* dalam bidang STEM.

HASIL DAN PEMBAHASAN

Hasil

Proses pengumpulan data dilakukan dengan crawling di platform *Twitter* menggunakan *Tweet Harvest*, dibatasi hingga 1200 *tweet* dari rentang waktu 2018-2024. Rentang ini dipilih untuk memperluas cakupan data yang lebih beragam dan representatif dalam analisis sentimen terkait kesetaraan *gender* di bidang STEM. Kata kunci yang digunakan adalah "kesetaraan *gender*" dan "STEM". Dari proses ini, diperoleh 1200 *tweet* yang dibagi menjadi 960 *tweet* untuk data latih (80%) dan 240 *tweet* untuk data uji (20%). Sentimen dilabeli secara manual oleh pakar, dengan label 0 untuk ulasan negatif dan 1 untuk ulasan positif.

Tahap *preprocessing* mencakup normalisasi teks sesuai Kamus Besar Bahasa Indonesia (KBBI), penghapusan karakter tidak relevan, tokenisasi untuk memecah teks menjadi kata, dan

stemming untuk mengubah kata ke bentuk dasar. Data hasil *preprocessing* dapat dilihat pada tabel 1.

Setelah *preprocessing*, teks diubah menjadi representasi numerik menggunakan teknik tokenisasi dan *padding*. Proses ini memungkinkan teks untuk diproses oleh model *Long Short-Term Memory* (LSTM). Tokenisasi dilakukan menggunakan pustaka NLTK dengan modul *word_tokenize* dan *punkt*. Pada tahap ini, setiap teks dipecah menjadi unit kata (token), dimana setiap kata dianggap sebagai elemen terpisah. Modul *punkt* digunakan untuk memastikan pengenalan tanda baca dan memisahkannya dari kata-kata, sehingga tokenisasi lebih akurat.

Tabel 1. Hasil data yang diperoleh dari *twitter*

<i>Full_text</i>	<i>Cleaned_text</i>	Panjang Kata	Label
Perusahaan yang sibuk mikirin <i>gender equality</i> 🧑‍🤝‍🧑 bukannya fokus ke profit. Teknologi tuh butuh skill, bukan kuota. 🙄	perusahaan yang sibuk mikirin <i>gender equality</i> seharusnya fokus ke profit teknologi butuh skill bukan kuota	Sebelum preprocessing: 18 Kata Setelah preprocessing: 15 Kata	Positif
Kesetaraan gender di STEM? Kayaknya malah bikin standar kerja turun. Realitanya nggak seindah narasi. 🙄🚫	kesetaraan gender di stem sepertinya membuat standar kerja turun realitanya tidak seindah narasi	Sebelum preprocessing: 15 Kata Setelah preprocessing: 13 Kata	Negatif

Setelah tokenisasi, *padding* ditambahkan untuk memastikan semua input memiliki panjang yang sama, terutama karena model LSTM membutuhkan input dengan dimensi konsisten. *Padding* dilakukan dengan menambahkan nilai nol (0) di akhir atau awal token, sehingga teks pendek memiliki panjang yang sama dengan teks lainnya. Proses tokenisasi dan *padding* ini menghasilkan representasi numerik teks yang dapat dilihat pada tabel 2.

Tabel 2. Hasil tokenisasi

<i>Preprocessing</i>	<i>Tokenize</i>
perusahaan yang sibuk mikirin <i>gender equality</i> seharusnya fokus ke profit teknologi butuh skill bukan kuota	['perusahaan', 'yang', 'sibuk', 'mikiran', 'gender', 'equality', 'seharusnya', 'fokus', 'ke', 'profit', 'teknologi', 'butuh', 'skill', 'bukan', 'kuota']

```
# Inisialisasi Tokenizer
tokenizer = Tokenizer()
# Fit tokenizer pada data yang sudah diproses
tokenizer.fit_on_texts(df['cleaned_text'])
# Mengubah teks yang sudah diproses menjadi urutan angka
X = tokenizer.texts_to_sequences(df['cleaned_text'])
# Menentukan panjang input yang seragam (maksimal 100 kata)
maxlen = 100 # Misalnya, panjang input teks diset ke 100 kata
# Padding agar semua input memiliki panjang yang sama
X_pad = pad_sequences(X, maxlen=maxlen)
# Menampilkan ukuran data setelah padding
print(f"Shape X_pad: {X_pad.shape}")
print(X_pad)
```

Shape X_pad: (1200, 100)

```
[[ 0  0  0 ... 39 181 108]
 [ 0  0  0 ... 109  5  3]
 [ 0  0  0 ...  3 132 108]
 ...
 [ 0  0  0 ... 57 345 148]
 [ 0  0  0 ... 60 276  4]
 [ 0  0  0 ...  2 102 31]]
```

Gambar 2. Mengubah teks menjadi numerik

Pada gambar 2, setelah tokenisasi, setiap token diubah menjadi representasi numerik menggunakan *word embedding* untuk diproses oleh model. *Padding* ditambahkan untuk memastikan semua input memiliki panjang yang sama, dengan menambahkan nilai numerik

(misalnya nol) pada teks yang lebih pendek. Token yang telah diubah menjadi angka kemudian diubah menjadi vektor berdimensi tetap melalui *embedding layer*, yang membantu model memahami konteks kata dalam kalimat.

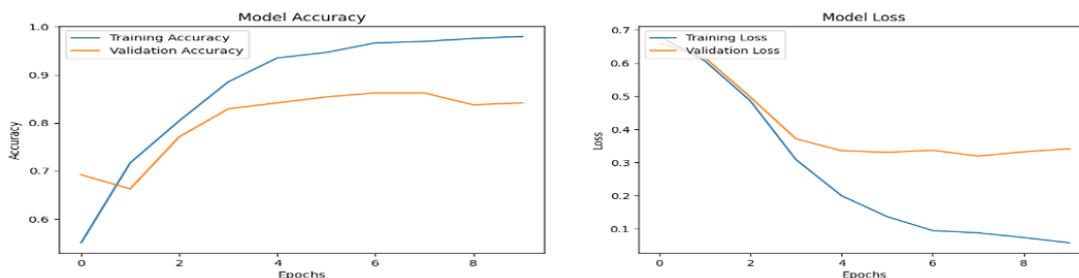
Proses *data mining* dilakukan dengan membangun dan melatih model LSTM. Struktur model terdiri dari *embedding layer* untuk merepresentasikan kata sebagai vektor dengan dimensi 128, LSTM *layer* untuk menangkap pola sekuensial dalam data teks, dan *dense layer* dengan fungsi aktivasi *sigmoid* untuk klasifikasi. *Dropout* sebesar 0,2 diterapkan untuk mencegah *overfitting*, dan *binary cross-entropy* digunakan sebagai fungsi *loss*. *Optimizer Adam* digunakan untuk efisiensi pembaruan parameter. Model dilatih selama 10 *epoch* dengan ukuran *batch* 64.

Tabel 3. Hasil pelatihan model

<i>Epoch</i>	Akurasi Pelatihan	Loss Pelatihan	Akurasi Validasi	Loss Validasi
1	55,00%	0,6805	69,17%	0,6606
2	71,67%	0,6067	66,25%	0,6164
3	80,42%	0,4861	77,08%	0,4975
4	88,54%	0,3091	82,92%	0,3719
5	93,54%	0,2003	84,17%	0,3359
6	94,69%	0,1373	85,42%	0,3311
7	96,67%	0,0950	86,25%	0,3371
8	96,98%	0,0883	86,25%	0,3196
9	97,60%	0,0741	83,75%	0,3326
10	98,02%	0,0583	84,17%	0,3415

Pada tabel 3 adalah hasil akurasi pelatihan meningkat dari 55,00% pada *epoch* pertama hingga 98,02% pada *epoch* ke-10, dengan loss pelatihan menurun dari 0,6805 menjadi 0,0583. Namun, akurasi validasi mencapai puncaknya pada *epoch* ke-7 sebesar 86,25% dan menunjukkan fluktuasi kecil setelahnya. Hal ini menunjukkan potensi *overfitting*, di mana model terlalu menyesuaikan diri pada data pelatihan, terlihat dari *loss* validasi yang mulai meningkat setelah *epoch* ke-7. Meskipun ada indikasi *overfitting*, akurasi validasi yang konsisten di kisaran 84%-86% menunjukkan model memiliki kemampuan generalisasi yang baik. Model terbukti andal dalam menangkap pola kompleks pada data teks berbahasa Indonesia.

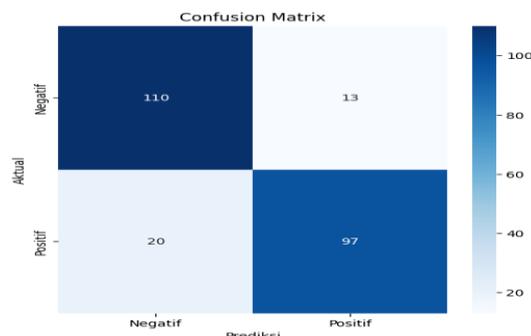
Pada gambar 3 adalah model akurasi dan loss memperlihatkan bahwa model mencapai akurasi validasi tertinggi sebesar 86,25% pada *epoch* ke-7, dengan stabilitas akurasi yang baik hingga akhir pelatihan. Penurunan loss pelatihan dan validasi mengindikasikan bahwa model belajar dengan efektif, meskipun terdapat sedikit indikasi *overfitting* setelah *epoch* ke-7, yang ditunjukkan oleh perbedaan antara loss pelatihan dan validasi.



Gambar 3. Model akurasi dan model loss

Gambar 4 adalah hasil dari *confusion matrix* yang menunjukkan bahwa model berhasil mengklasifikasikan 97 data positif (*true positives*) dan 110 data negatif (*true negatives*) dengan

benar. Namun, terdapat 13 prediksi positif palsu (*false positives*) dan 20 prediksi negatif palsu (*false negatives*). Hasil ini mencerminkan bahwa model memiliki tingkat akurasi dan presisi yang tinggi, meskipun masih terdapat ruang untuk meningkatkan sensitivitas dalam mendeteksi data positif.



Gambar 4. *Confusion matrix*

Tabel 4. Hasil evaluasi kinerja model

Akurasi	Presisi	Recall	F1-Score
86,25%	88,18%	82,20%	0,85%

Tabel 4 menunjukkan kinerja model berdasarkan beberapa metrik evaluasi. Model mencapai akurasi sebesar 86,25%, yang berarti model mampu memprediksi dengan benar sebanyak 86,25% dari keseluruhan data. Presisi tercatat sebesar 88,18%, yang menandakan bahwa dari seluruh prediksi positif yang dibuat, 88,18% adalah benar. *Recall* sebesar 82,20% menunjukkan bahwa model dapat mendeteksi 82,20% dari semua data positif yang sebenarnya. *F1-Score* sebesar 0,85% (kemungkinan salah tulis, harusnya 85%) mencerminkan keseimbangan antara presisi dan recall, memberikan gambaran umum mengenai kinerja model dalam situasi dengan distribusi kelas yang tidak seimbang.

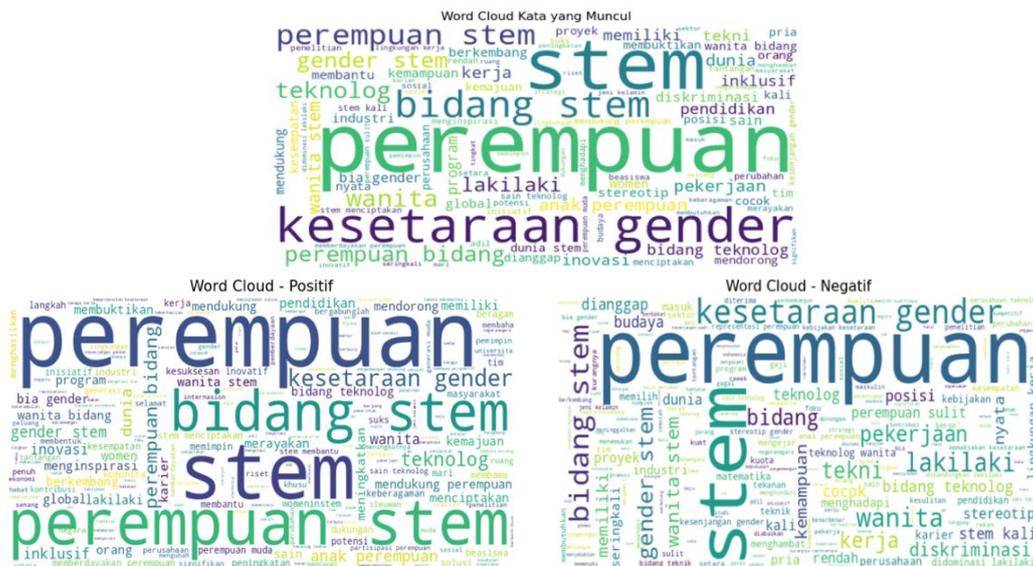
Guna mengukur kemampuan generalisasi model, dilakukan uji coba dengan kalimat-kalimat di luar dataset. Hasilnya, model berhasil mengenali sentimen positif dan negatif. Sentimen negatif teridentifikasi pada kalimat yang menggambarkan tantangan, seperti diskriminasi, sementara sentimen positif ditemukan pada kalimat yang menekankan keberhasilan, seperti peningkatan perempuan di STEM. Hasil ini menunjukkan kemampuan model memahami pola bahasa dan konteks sentimen secara umum. Tabel 5 menyajikan hasil uji model dengan kalimat di luar dataset.

Tabel 5. Uji model menggunakan kalimat di luar dataset

Sentimen	Label
Perempuan tidak memiliki jaringan profesional yang kuat di STEM	<i>Negative</i>
Kesetaraan gender di STEM membuka peluang yang lebih besar bagi perempuan.	<i>Positive</i>

Visualisasi *word cloud* memberikan wawasan mengenai distribusi kata dalam analisis sentimen. *Word cloud* dihasilkan dengan menghitung frekuensi kata setelah *preprocessing*, termasuk normalisasi, tokenisasi, dan *stemming*. Kata dengan frekuensi tinggi ditampilkan lebih besar, sementara yang rendah lebih kecil. Visualisasi ini menampilkan kata-kata seperti "kemajuan," "diskriminasi," dan "kesetaraan," yang mencerminkan tema utama terkait kesetaraan *gender* di STEM. *Word cloud* membantu mengidentifikasi pola sentimen yang relevan. Sebaliknya, kata-kata dengan ukuran lebih kecil muncul lebih jarang dalam data. Visualisasi ini membantu dalam mengidentifikasi pola sentimen yang dominan, memahami

topik yang paling sering dibahas, serta memberikan wawasan tambahan dalam interpretasi hasil analisis sentimen menggunakan algoritma LSTM. Berikut adalah hasil *Word Cloud* dari dataset yang diproses dengan algoritma LSTM dapat dilihat pada gambar 5.



Gambar 5. *Word cloud*

Pembahasan

Hasil temuan dari model LSTM menunjukkan kinerja yang baik dalam analisis sentimen, dengan akurasi validasi sebesar 86,25%. Angka ini mencerminkan kemampuan model dalam memprediksi sentimen positif atau negatif terkait kesetaraan *gender* menggunakan data validasi yang tidak dilibatkan dalam pelatihan. Meskipun demikian, terdapat indikasi *overfitting* setelah *epoch* ke-7, yang terlihat pada grafik akurasi dan loss. Akurasi pelatihan terus meningkat, namun akurasi validasi stagnan atau menurun, menunjukkan model terlalu spesifik pada data pelatihan dan kurang mampu menggeneralisasi data baru.

Model LSTM pada analisis kesetaraan *gender* dapat mengidentifikasi perbedaan sentimen terkait isu *gender* di bidang STEM. Namun, model ini terbatas dalam mengenali ironi atau sarkasme yang sering muncul dalam diskusi kesetaraan. Misalnya, komentar yang mengandung stereotip *gender* atau ketidaksetaraan akses bagi perempuan kadang sulit terdeteksi karena kompleksitas bahasa. Untuk mengatasi hal ini, integrasi model transformer seperti *Bidirectional Encoder Representations from Transformers* (BERT) atau *Generative Pre-trained Transformer* (GPT) dapat meningkatkan akurasi dalam mengenali sentimen yang lebih kompleks.

Faktor utama yang mendukung hasil ini adalah pemilihan dataset *Twitter* yang relevan, yang berisi beragam pendapat tentang kesetaraan *gender* di bidang STEM. Dataset ini memungkinkan model untuk mengenali berbagai bentuk sentimen, baik positif maupun negatif. Selain itu, penggunaan class weights untuk menangani ketidakseimbangan data turut berperan dalam meningkatkan kinerja model.

Pada penelitian Isnain et al. (2022) dan Rini et al. (2022) yang menggunakan *naive bayes* dan SVM. Sementara penelitian kami menggunakan model LSTM lebih efektif dalam memahami konteks antar kata dalam analisis sentimen kesetaraan *gender* di bidang STEM. Kemampuannya dalam menangkap pola bahasa yang kompleks memungkinkan analisis opini yang lebih mendalam, terutama untuk sentimen implisit. Selain itu, model ini memberikan wawasan lebih luas terkait faktor sosial, budaya, dan kebijakan yang memengaruhi persepsi kesetaraan *gender* serta dampak tindakan afirmatif di bidang STEM.

SIMPULAN

Penelitian ini menunjukkan bahwa model LSTM dapat menjadi alat yang efektif dalam menganalisis sentimen terkait kesetaraan *gender* di bidang STEM, dengan hasil yang stabil dan akurat. Temuan utama penelitian ini mengungkapkan adanya perbedaan yang signifikan antara sentimen positif yang mendukung kesetaraan dan sentimen negatif yang mencerminkan tantangan yang dihadapi perempuan di sektor tersebut. Penerapan LSTM memberikan pemahaman yang lebih mendalam terkait hubungan antar kata, yang memungkinkan analisis sentimen yang lebih kaya dan komprehensif dibandingkan dengan pendekatan konvensional. Keberhasilan model ini membuka jalan bagi penerapan metode pembelajaran mesin yang lebih canggih dalam memahami dinamika sosial yang kompleks, serta memberikan landasan bagi penelitian lanjutan mengenai pengaruh faktor sosial-budaya dalam persepsi kesetaraan *gender* di bidang STEM.

REFERENSI

- Amriyati, A., Nurbaiti, S., Adiasih, N., Septiyani, S., Budhianti, M. I., Suliantari, A., & Nainggolan, F. L. (2023). Perlindungan Pekerja Perempuan Dalam Kebijakan Ramah Keluarga Di Tempat Kerja: Sosialisasi Pada Serikat Pekerja. *Jurnal Abdimas Bina Bangsa*, 4(2), 1312-1322.
- Arsi, P., & Waluyo, R. (2021). Analisis Sentimen Wacana Pemindahan Ibu Kota Indonesia Menggunakan Algoritma Support Vector Machine (SVM). *Jurnal Teknologi Informasi Dan Ilmu Komputer (JTIK)*, 8(1), 147–156. <https://doi.org/10.25126/jtik.0813944>
- Azrul, A., Purnamasari, A. I., & Ali, I. (2024). Analisis Sentimen Pengguna Twitter Terhadap Perkembangan Artificial Intelligence Dengan Penerapan Algoritma Long Short-Term Memory (LSTM). *Jurnal Mahasiswa Teknik Informatika*, 8(1), 413–421. <https://doi.org/10.36040/jati.v8i1.8416>
- Cahyadi, R., Damayanti, A., & Aryadani, D. (2020). Recurrent Neural Network (RNN) Dengan Long Short Term Memory (LSTM) Untuk Analisis Sentimen Data Instagram. *Jurnal Informatika Dan Komputer*, 5(1), 1–9.
- Fouad, S., & Alkooheji, E. (2023, February). Sentiment analysis for women in stem using twitter and transfer learning models. *The 7th international conference on semantic computing (ICSC)*, 227-234. Laguna Hills, CA, USA: IEEE. <https://doi.org/10.1109/ICSC56153.2023.00045>
- Hasiholan, A., Cholissodin, I., & Yudistira, N. (2022). Analisis Sentimen Tweet Covid-19 Varian Omicron pada Platform Media Sosial Twitter menggunakan Metode LSTM berbasis Multi Fungsi Aktivasi dan GLOVE. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer (JPTIK)*, 6(10), 4653–4661.
- Isnain, A. R., Sulistiani, H., Hurohman, B. M., Nurkholis, A., & Styawati. (2022). Analisis Perbandingan Algoritma LSTM dan Naive Bayes untuk Analisis Sentimen. *Jurnal Edukasi Dan Penelitian Informatika (JEPIN)*, 8(2), 299–303. <https://doi.org/10.26418/jp.v8i2.54704>
- Lidinillah, E. R., Rohana, T., & Juwita, A. R. (2023). Analisis sentimen Twitter terhadap Steam menggunakan algoritma logistic regression dan support vector machine. *Teknosains: Jurnal Sains, Teknologi Dan Informatika*, 10(2), 154–164. <https://doi.org/10.37373/tekno.v10i2.440>
- Meoli, A., Piva, E., & Righi, H. (2024). Meoli, A., Piva, E., & Righi, H. (2024). Missing women in STEM occupations: The impact of university education on the gender gap in graduates' transition to work. *Research Policy*, 53(8), 1–16. <https://doi.org/10.1016/j.respol.2024.105072>

- Naufal, H. (2022). Skripsi Analisis Sentimen Masyarakat Terhadap Vaksin Covid-19 Menggunakan Metode Recurrent Neural Network Dengan Long Short-Term Memory [Thesis (Skripsi), Universitas Pakuan]. <http://eprints.unpak.ac.id/id/eprint/2696>
- Pane, O. O., Sihombing, S., Simbolon, D., Zalukhu, D., & Lumbantobing, R. (2024). Kesetaraan Gender. *Jurnal Ilmu Hukum, Sosial, Dan Humaniora*, 2(6), 298–7304.
- Rini, R. Y., Mutaqin, M. F. T., & Fajari, L. E. W. (2022). Implementasi STEAM dalam Mengkonstruksi Kesetaraan Gender pada Anak Usia Dini. *Jurnal Obsesi: Jurnal Pendidikan Anak Usia Dini*, 6(6), 6661-6674. <https://doi.org/10.31004/obsesi.v6i6.3436>
- Rumaisa, F., Puspitarani, Y., Rosita, A., Zakiah, A., & Violina, S. (2021). Penerapan Natural Language Processing (NLP) di bidang pendidikan. *Jurnal Inovasi Masyarakat*, 1(3), 232-235. <https://doi.org/10.33197/jim.vol1.iss3.2021.799>
- Sedana, N. M. K., Wijaya, I. N. S. W., & Arthana, I. K. R. (2024). Analisis Sentimen Berbahasa Inggris Dengan Metode Lstm Studi Kasus Berita Online Pariwisata Bali. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 11(6), 1325-1334. <https://doi.org/10.25126/jtiik.1168792>
- Sudirman, F. A., & Susilawaty, F. T. (2022). Kesetaraan Gender Dalam Tujuan Pembangunan Berkelanjutan (Sdgs): Suatu Reviuw Literatur Sistematis. *Journal Publicuho*, 5(4), 995-1010. <https://doi.org/10.35817/publicuho.v5i4.41>
- Syah, R. I., Hoiriyah, H., & Walid, M. (2023). Analisis Sentimen Pengguna Media Sosial Terhadap Aplikasi M-Health Peduli Lindungi Dengan Metode Lexicon Based Dan Naïve Bayes. *Indonesian Journal of Business Intelligence (IJUBI)*, 6(1) 43–54. <https://doi.org/10.21927/ijubi.v6i1.3275>
- Wahyuni, W. (2022). Analisis Sentimen terhadap Opini Feminisme Menggunakan Metode Naive Bayes. *Jurnal Informatika Ekonomi Bisnis*, 148-153. <https://doi.org/10.37034/infeb.v4i4.162>
- Yazidi, M., Ramdani, R., & Rifai, M. (2023). Perbandingan Kebijakan Perspektif Kesetaraan Gender Indonesia dan Thailand Partisipasi Masyarakat Dalam Kesetaraan Gender Untuk Membuat Perspektif Kebijakan Pemerintahan di Indonesia dan Thailand. *Innovative: Journal Of Social Science Research*, 3(5), 3167-3178.
- Yuniarossy, B. A., Hindrayani, K. M., & Damaliana, A. T. (2024). Analisis Sentimen Terhadap Isu Feminisme Di Twitter Menggunakan Model Convolutional Neural Network (CNN). *Jurnal Ilmiah Pendidikan Matematika Dan Statistika*, 5(10), 477–491. <https://doi.org/https://doi.org/10.46306/lb.v5i1.585>
- Zharifa, A. H. A., & Ujianto, E. I. H. (2024). Analisis Sentimen Publik di Twitter Pasca Debat Kelima Pilpres 2024 dengan Naive Bayes. *Edumatic: Jurnal Pendidikan Informatika*, 8(2), 754-763. <https://doi.org/10.29408/edumatic.v8i2.28048>