



# Penerapan *Deep Learning* dan Analisis Sentimen terhadap Gap Kompetensi Lulusan Lembaga Pendidikan dan Pelatihan Vokasi terhadap Dunia Kerja dengan Metode *Long Short-Term Memory (LSTM)*

Susilawati\*, Zulham Sitorus, Muhammad Iqbal, Darmeli Nasution, Rian Farta Wijaya

Pascasarjana, Magister Teknologi Informasi, Universitas Pembangunan Pancabudi, Medan, Indonesia

Email: [1susiyahya@gmail.com](mailto:susiyahya@gmail.com), [2zulhamsitorus@dosen.pancabudi.ac.id](mailto:zulhamsitorus@dosen.pancabudi.ac.id), [3muhammadiqbal@dosen.pancabudi.ac.id](mailto:muhammadiqbal@dosen.pancabudi.ac.id),

[4darmelinasion@gmail.com](mailto:darmelinasion@gmail.com), [5rianfartawijaya@dosen.pancabudi.ac.id](mailto:rianfartawijaya@dosen.pancabudi.ac.id)

Email Penulis Korenspondensi: [susiyahya@gmail.com](mailto:susiyahya@gmail.com)

**ABSTRAK**- Kesenjangan antara kompetensi lulusan pendidikan vokasi dan kebutuhan dunia kerja masih menjadi tantangan signifikan di Indonesia. Penelitian ini bertujuan untuk menganalisis persepsi alumni terhadap kesesuaian kompetensi yang diperoleh selama studi di LP3I Banda Aceh dengan tuntutan nyata di dunia kerja. Penelitian ini menggunakan pendekatan kuantitatif dengan metode deep learning berbasis Long Short-Term Memory (LSTM). Data dikumpulkan melalui survei online berupa tanggapan terbuka dari 934 alumni, kemudian dilakukan proses preprocessing, tokenisasi, pelabelan sentimen berbasis leksikon, dan dibagi menjadi data latih dan uji. Model yang dikembangkan terdiri dari LSTM murni, LSTM dengan class weight, dan Bidirectional LSTM (BiLSTM). Hasil menunjukkan bahwa model BiLSTM memberikan performa terbaik dengan akurasi sebesar 90% dan nilai weighted F1-score sebesar 0.91. Selain itu, ditemukan bahwa 44,5% responden memberikan sentimen netral atau negatif, yang mengindikasikan adanya gap antara kompetensi yang diperoleh dengan kebutuhan industri. Temuan ini menegaskan pentingnya evaluasi kurikulum dan sinergi antara lembaga pendidikan vokasi dan dunia usaha. Studi ini menunjukkan bahwa pendekatan deep learning dapat menjadi alat evaluatif yang efisien dan objektif untuk pemetaan kompetensi lulusan.

**Kata kunci:** analisis sentimen, deep learning, LSTM, kompetensi lulusan, pendidikan vokasi.

**ABSTRACT** - The gap between vocational graduates' competencies and labor market demands remains a pressing issue in Indonesia. This study aims to analyze alumni perceptions regarding the alignment between competencies acquired during their studies at LP3I Banda Aceh and real-world job requirements. A quantitative approach was adopted using a deep learning method based on Long Short-Term Memory (LSTM). Data were collected through an online survey containing open-ended responses from 934 alumni, followed by preprocessing, tokenization, lexicon-based sentiment labeling, and data splitting into training and testing sets. The models developed included pure LSTM, LSTM with class weights, and Bidirectional LSTM (BiLSTM). Results indicate that BiLSTM achieved the highest performance with 90% accuracy and a weighted F1-score of 0.91. Additionally, 44.5% of respondents expressed neutral or negative sentiments, highlighting a mismatch between acquired competencies and industry demands. These findings underscore the urgency of curriculum evaluation and stronger collaboration between vocational institutions and the labor market. This study demonstrates that deep learning offers an efficient and objective tool for competency mapping in vocational education.

**Keywords:** sentiment analysis, deep learning, LSTM, graduate competencies, vocational education.

## 1. PENDAHULUAN

Kemajuan teknologi yang begitu cepat telah membawa perubahan besar pada dunia industri. Perubahan ini bukan hanya memengaruhi bagaimana barang dibuat atau bagaimana perusahaan dikelola, tetapi juga memengaruhi jenis pekerjaan yang ada. Muncul berbagai macam pekerjaan baru yang berhubungan dengan teknologi digital dan semakin banyak dicari, contohnya ahli data, pengembang web, spesialis pemasaran digital, hingga pembuat konten dan tokoh berpengaruh di media sosial. Pekerjaan-pekerjaan ini membutuhkan keterampilan digital khusus dan pemahaman tentang perubahan yang terjadi di pasar serta bagaimana konsumen bertindak. Karena perubahan ini, persaingan untuk mendapatkan pekerjaan semakin ketat. Sekarang, memiliki ijazah atau nilai bagus saja tidak cukup. Dunia industri mencari orang-orang yang tidak hanya ahli dalam bidangnya (kemampuan teknis), tetapi juga memiliki kemampuan lain yang tidak berhubungan langsung dengan bidangnya (kemampuan non-teknis). Contohnya, kemampuan berpikir kritis, memecahkan masalah, berkomunikasi dengan baik, bekerja sama dengan orang lain, dan beradaptasi dengan perubahan yang terjadi dengan cepat. Kombinasi antara kemampuan teknis dan non-teknis ini sangat penting agar lulusan siap dan mampu bersaing di dunia kerja saat ini.

LP3I Banda Aceh, sebagai salah satu lembaga pendidikan dan pelatihan vokasi, memiliki misi melahirkan lulusan yang siap kerja. Namun, di era digital ini LP3I Banda Aceh juga menghadapi tantangan yang kompleks dalam memastikan relevansi kurikulum dan kualitas lulusan yang dihasilkan disetiap tahunnya. Salah satu tantangan utama adalah bagaimana memastikan bahwa kompetensi yang diajarkan di kelas sejalan dengan kebutuhan industri yang terus berubah. Selain itu, LP3I Banda Aceh juga perlu memastikan bahwa lulusannya tidak hanya memiliki pengetahuan teknis yang memadai, tetapi juga dilengkapi dengan soft skills yang dibutuhkan di dunia kerja, seperti kemampuan berkomunikasi, bekerja dalam tim, dan beradaptasi dengan perubahan. Berdasarkan hal tersebut diatas maka penelitian ini akan mengkaji lebih dalam mengenai gap kompetensi yang dirasakan oleh lulusan LP3I Banda Aceh dengan tuntutan dunia kerja.



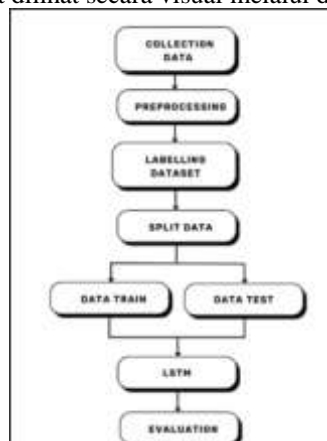
Dengan memanfaatkan teknologi deep learning dan analisis sentiment menggunakan metode long short term memory (Lstm) , kita dapat mengidentifikasi dengan lebih akurat kompetensi apa saja yang masih kurang dimiliki oleh lulusan. Deep Learning (DL) merupakan salah satu teknik dalam kecerdasan buatan yang berbasis pada jaringan saraf tiruan dan telah mengalami perkembangan pesat dalam beberapa tahun terakhir. Teknologi ini tidak terbatas pada satu bidang saja, melainkan bersifat general-purpose dan mampu diterapkan untuk menyelesaikan berbagai permasalahan kompleks lintas disiplin. Dalam konteks Educational Data Mining (EDM), penerapan DL mulai berkembang sejak sekitar tahun 2015 dan terus menunjukkan peningkatan secara signifikan. Pendekatan komputasional ini mulai dimanfaatkan dalam dunia pendidikan untuk menganalisis data pembelajaran, termasuk dalam mengevaluasi kompetensi lulusan [1]. Salah satu pendekatan yang umum digunakan dalam analisis sentimen adalah Deep Learning, yang bekerja dengan cara mengekstraksi informasi dari data melalui jaringan saraf tiruan (neural network). Model ini belajar secara bertahap dengan meminimalkan kesalahan prediksi atau *error* selama proses pelatihan. Dalam klasifikasi teks, salah satu arsitektur deep learning yang banyak digunakan adalah *Long Short-Term Memory* (LSTM), karena kemampuannya dalam memahami urutan kata dan konteks kalimat secara lebih mendalam[2]. Analisis sentimen, atau yang dikenal juga dengan opinion mining, merupakan bagian dari proses Natural Language Processing (NLP) yang digunakan untuk mengidentifikasi dan mengevaluasi sikap, opini, atau emosi seseorang terhadap suatu topik, produk, atau layanan. Teknologi ini memungkinkan sistem untuk mengekstraksi makna sentimen dari data teks, seperti komentar, ulasan, atau tanggapan dalam kuesioner. Dalam konteks pendidikan, analisis sentimen dapat dimanfaatkan untuk menggali persepsi alumni, dosen, maupun mitra industri terhadap lembaga pendidikan. Informasi tersebut menjadi dasar penting dalam merancang perbaikan kurikulum, proses pembelajaran, dan pengembangan fasilitas agar lebih selaras dengan kebutuhan dunia kerja[3]

Pada penelitian sebelumnya yang dilakukan oleh (Andi Aljabar, Arifin A,2022)[4] menggunakan metode LSTM memperlihatkan tingkat akurasi sebesar 97% dan loss sebesar 12%. Selanjutnya pada penelitian yang dilakukan oleh (Angreiny R, Axcel W & Green A.S,2023)[5] yang menggunakan jumlah data sebanyak 15.093 tweet berhasil menunjukkan bahwa model BiLSTM memiliki akurasi tertinggi sebesar 86%, diikuti model GRU dengan akurasi 86%, model LSTM dengan akurasi 85%. Sementara itu pada penelitian yang lainnya yang diteliti oleh (Auliya,Heni, Bagus,Andi & Styawati, 2022) [6], membandingkan kinerja metode Long Short Therm Memory dengan Naïve Bayes, hasil yang diperoleh dari penelitian dimana metode LSTM memiliki kinerja yang lebih baik bila dibandingkan dengan Naïve Bayes. Metode LSTM menghasilkan nilai akurasi, presisi dan recall sebesar 83.33%. Sedangkan metode Naïve Bayes memiliki nilai akurasi, presisi dan recall sebesar 82%. Berdasarkan dari tiga penelitian yang menjadi referensi jurnal penelitian dengan hasil penelitiannya dijelaskan diatas, menunjukkan bahwa algoritma LSTM memiliki akurasi yang cukup tinggi dalam menganalisis sentiment dengan teks yang kompleks dibandingkan algoritma klasifikasi yang lainnya.

Penelitian ini bertujuan untuk mengidentifikasi kompetensi-kompetensi spesifik yang masih mengalami kesenjangan antara lulusan LP3I Banda Aceh dengan tuntutan dunia kerja saat ini. Selain itu, penelitian ini juga berupaya memetakan kebutuhan dunia kerja di wilayah Provinsi Aceh guna memperoleh pemahaman yang lebih kontekstual terhadap ekspektasi industri terhadap lulusan pendidikan vokasi. Melalui pendekatan analisis sentimen, penelitian ini menganalisis persepsi lulusan terkait pengalaman mereka dalam dunia kerja, khususnya dalam kaitannya dengan relevansi kompetensi yang diperoleh selama masa studi. Dengan memanfaatkan metode Deep Learning, khususnya algoritma Long Short-Term Memory (LSTM), penelitian ini mengembangkan model analisis yang mampu mengidentifikasi gap kompetensi secara lebih akurat dan efisien. Hasil dari analisis ini diharapkan dapat digunakan sebagai dasar dalam merumuskan rekomendasi perbaikan kurikulum berbasis data untuk meningkatkan relevansi program pendidikan dengan kebutuhan dunia kerja, sehingga lulusan LP3I Banda Aceh memiliki daya saing yang lebih baik di pasar tenaga kerja.

## 2. METODOLOGI PENELITIAN

Alur lengkap dari proses penelitian ini dapat dilihat secara visual melalui diagram yang disajikan pada gambar berikut



**Gambar 1.** Alur Penelitian

1. *Collection data* atau tahap pengumpulan data dalam penelitian ini dilakukan untuk memperoleh informasi yang relevan dengan fokus kajian. Proses ini dilaksanakan melalui penyebaran kuesioner atau angket secara online menggunakan media google form yang ditujukan kepada alumni LP3I Banda Aceh yang telah lulus pada rentang tahun 2017 hingga 2024.
2. *Preprocessing Data*, data yang telah dikumpulkan biasanya belum siap untuk langsung digunakan dalam pemodelan. Pada tahap preprocessing, data akan dibersihkan, diubah formatnya, dan diubah menjadi *bentuk* yang sesuai untuk digunakan dalam algoritma pembelajaran mesin. Proses ini meliputi kegiatan Langkah-langkah preprocessing melibatkan text cleaning, case folding, tokenisasi, stemming dan penggabungan hasil stemming [7]
3. *Labeling Dataset*, pada tahap ini, setiap data teks diberikan label atau kelas tertentu yang merepresentasikan kategori sentimen. Proses pelabelan ini merupakan komponen penting dalam pelatihan model, karena model akan dilatih untuk mengenali pola dari input berdasarkan label yang telah ditetapkan. Dengan demikian, model dapat mempelajari hubungan antara data masukan dan kategori sentimen secara sistematis, guna menghasilkan prediksi yang akurat pada data baru.[8]
4. *Split data* adalah membagi dataset menjadi dua bagian, yaitu data pelatihan (training data) dan data pengujian (testing data). Tujuan dari pembagian ini adalah untuk memastikan bahwa model dapat dilatih menggunakan sebagian data yang tersedia, sementara sisanya digunakan untuk menguji kemampuan model dalam melakukan prediksi terhadap data yang belum pernah dilihat sebelumnya. Dengan demikian, kinerja model dapat dievaluasi secara objektif dan akurat.[9]
5. **Data Train dan Data Test**  
Data Train Digunakan untuk melatih model agar dapat mengenali pola dalam data dan memahami hubungan antara input teks dan label sentimen.  
Data Test Digunakan untuk menguji model yang telah dilatih agar dapat diketahui tingkat akurasi terhadap data baru.
6. Algoritma *Long Short-Term Memory (LSTM)* digunakan sebagai model utama untuk melakukan klasifikasi sentimen. Pemilihan LSTM didasarkan pada kemampuannya dalam mengolah data berurutan serta memahami hubungan kontekstual antar kata dalam sebuah kalimat. Keunggulan ini menjadikan LSTM sangat sesuai untuk analisis teks, karena mampu menangkap makna yang tersembunyi dalam struktur bahasa secara lebih mendalam dibandingkan metode konvensional lainnya.[10]
7. Tahapan terakhir dalam proses penelitian adalah evaluasi terhadap kinerja model. Penilaian dilakukan dengan menggunakan sejumlah metrik evaluasi seperti akurasi, presisi, *recall*, dan *F1-score* guna mengukur efektivitas model LSTM dalam melakukan klasifikasi sentimen. Evaluasi ini memiliki peran penting karena menjadi dasar dalam menilai keberhasilan model sekaligus menjadi acuan dalam merumuskan kesimpulan serta rekomendasi yang berbasis hasil analisis data secara objektif.

## 2.1 Penerapan Deeplearning

Deep Learning merupakan salah satu cabang dari machine learning yang menekankan pada pembelajaran representasi data melalui arsitektur jaringan saraf tiruan berlapis-lapis (multi-layer neural networks). Deep learning bekerja dengan cara memetakan data input ke target output melalui serangkaian transformasi non-linear yang dipelajari secara otomatis dari data. Setiap lapisan dalam jaringan bertanggung jawab untuk mengekstraksi fitur dari lapisan sebelumnya sehingga menghasilkan representasi yang semakin kompleks dan bermakna. Inilah yang membedakan deep learning dengan pendekatan machine learning konvensional yang hanya mampu menangkap pola-pola permukaan atau memerlukan rekayasa fitur manual.[11]

Manfaat utama dari deep learning terletak pada kemampuannya dalam menangani data berukuran besar dan kompleks seperti gambar, suara, maupun teks. Model ini dapat digunakan dalam berbagai aplikasi cerdas seperti pengenalan wajah, deteksi objek, klasifikasi teks, serta sistem rekomendasi. Salah satu kelebihan signifikan dari deep learning adalah kemampuannya untuk secara otomatis belajar dari data mentah tanpa memerlukan proses ekstraksi fitur manual, yang sering kali menjadi tantangan dalam machine learning tradisional. Selain itu, arsitektur deep learning seperti convolutional neural network (CNN) dan recurrent neural network (RNN), termasuk Long Short-Term Memory (LSTM), dirancang untuk memaksimalkan efisiensi pemrosesan data berdasarkan jenis input yang spesifik—misalnya, CNN untuk data spasial dan LSTM untuk data sekuensial. Dengan kedalaman arsitektur dan kemampuannya membentuk representasi hierarkis, deep learning menawarkan performa yang unggul dalam berbagai tugas klasifikasi dan prediksi berbasis data kompleks.[12]

## 2.2 Model LSTM (Long Short-Term Memory)

Long Short-Term Memory (LSTM) adalah salah satu arsitektur jaringan saraf tiruan yang dikembangkan untuk mengatasi keterbatasan dari Recurrent Neural Network (RNN), khususnya dalam mengingat informasi jangka panjang. LSTM dirancang untuk menghindari masalah *vanishing gradient* dengan menggunakan unit memori internal dan tiga jenis gerbang utama—yaitu *input gate*, *forget gate*, dan *output gate*—yang secara selektif mengatur aliran informasi dalam jaringan. Melalui mekanisme ini, LSTM dapat “menghafal” informasi penting dari urutan input dan secara efektif

membuang informasi yang tidak relevan seiring waktu. Hal ini membuat LSTM sangat cocok untuk tugas-tugas pemrosesan data sekuensial seperti teks dan sinyal waktu.[13]

Dalam konteks praktis, LSTM telah banyak digunakan dalam berbagai aplikasi seperti analisis sentimen, terjemahan mesin, prediksi pasar, dan deteksi penipuan. LSTM tidak hanya mampu menangkap konteks lokal dari satu kata ke kata lain, tetapi juga membentuk pemahaman konteks global melalui pemrosesan urutan panjang, sehingga menghasilkan output prediksi yang lebih akurat dalam berbagai tugas berbasis teks.[14]

### 3. HASIL DAN PEMBAHASAN

#### 3.1 Hasil Pengumpulan Data

Penelitian ini memanfaatkan data dari alumni LP3I College Banda Aceh yang dikumpulkan melalui survei daring menggunakan media Google Form. Instrumen pengumpulan data yang dirancang untuk menggali pandangan alumni terkait relevansi dan kompetensi yang mereka peroleh selama masa studi, terutama saat berhadapan langsung dengan dunia kerja. Salah satu komponen kunci dalam formulir tersebut adalah pertanyaan terbuka yang mendorong alumni untuk mengekspresikan pengalaman dan pendapat mereka mengenai kesenjangan kompetensi, mencakup aspek teknis, akademik, dan keterampilan non-teknis (soft skill). Data kualitatif yang bersifat naratif inilah yang menjadi sumber utama dalam proses analisis sentimen pada penelitian ini.

Setelah proses pengumpulan selesai, hasilnya dikompilasi ke dalam file berformat CSV bernama *Data Tesis\_real.csv*. File ini mencakup berbagai atribut responden, seperti nama lengkap, jenis kelamin, program studi, tahun kelulusan, dan status pekerjaan saat ini, hingga serangkaian pertanyaan yang menyentuh aspek kesiapan kerja, kesesuaian kompetensi, manfaat kompetensi di tempat kerja, kepuasan terhadap proses pembelajaran, serta pandangan terhadap adanya *gap* antara pendidikan yang diterima dan tuntutan di lapangan. Sebelum data digunakan untuk terlebih dilakukan serangkaian tahap validasi dan pembersihan guna memastikan kualitas dan relevansi data. Langkah pertama adalah memeriksa kelengkapan data, khususnya pada kolom tanggapan tentang *gap kompetensi*. Respon yang kosong, berisi karakter tak bermakna (seperti simbol acak, angka tanpa konteks, atau spasi kosong) dihapus agar tidak mempengaruhi proses analisis. Selanjutnya, dilakukan penyaringan lebih lanjut untuk mengeliminasi entri yang tidak mengandung makna semantik, misalnya tanggapan yang hanya berupa “-” atau “...” tanpa konteks opini. Tampilan bentuk data bisa dilihat pada gambar dibawah ini .

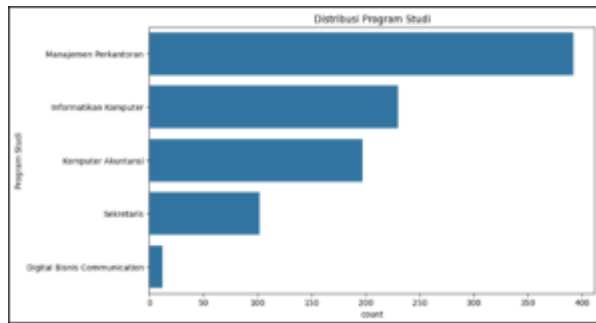


No	Nama	JK	Program Studi	Status	Kesiapan Kompetensi	Kepuasan	Gap Kompetensi		
1	Muhammad Laki-Laki	Laki	Digital Bus	2024	Belum Bekerja	Sangat Siap	Relatif	Belum ada, karena apa yang di pelajari di Lp3i sangat membantu saat dunia kerja	
2	Rubi Masra Perempu	Digital Bus	2024	Bekerja	Siap	Sangat Relatif	Mer Pua	Merurut saya, utk pendalaman skill udah baik namun kesiapan mental yg di ajarkan kurang dan perlu di asa	
3	Muhammad Laki-Laki	Laki	Digital Bus	2024	Bekerja	Sangat Siap	Sangat Relatif	Mer Pua	Tidak ada, saya bisa menggunakan semua skill yang saya dapatkan di LP3I
4	T. Muhamen Laki-Laki	Laki	Digital Bus	2024	W/taunaha	Sangat Siap	Sangat Relatif	Mer Pua	Tidak ada gnyus
5	Toma Rahms Perempu	Digital Bus	2024	Belum Bekerja	Sangat Siap	Sangat Relatif	Mer Pua	Tidak ada gnyus	
6	Sulhan Fat Laki-Laki	Laki	Digital Bus	2024	Bekerja	Sangat Siap	Sangat Relatif	Mer Pua	Tidak ada, BfH sesuai
7	Ahmad Rizki Laki-Laki	Laki	Digital Bus	2024	Belum Bekerja	Sangat Siap	Relatif	Mer Pua	skill teknis dan softskill masih sesuai tapi tetap harus diarah lagi saat masuk dunia kerja
8	Toma Rahms Perempu	Digital Bus	2024	Belum Bekerja	Sangat Siap	Sangat Relatif	Mer Pua	Ada, saya merasa kurang di teknis dan softskill	
9	Mita Nurya Perempu	Digital Bus	2024	Belum Bekerja	Sangat Relatif	Mer Pua	Sangat Relatif	Mer Pua	Ada, relevan dengan dunia kerja
10	M Afriyul Pr Laki-Laki	Laki	Digital Bus	2024	Bekerja	Sangat Siap	Sangat Relatif	Mer Pua	Pua ada tapi sedikit
11	ANZIR PUTRI Laki-Laki	Laki	Digital Bus	2024	Belum Bekerja	Sangat Relatif	Mer Pua	Mer Pua	Belum Bekerja
12	Siti Luthfia Perempu	Digital Bus	2024	Belum Bekerja	Sangat Relatif	Mer Pua	Mer Pua	Mer Pua	Belum Bekerja
13	Silvia Giosa Perempu	Komputer i	2017	Bekerja	Sangat Siap	Sangat Relatif	Mer Pua	Mer Pua	Tidak ada, hanya saja yg perlu ditambah jam pelajarannya adalah cara laporan pajak WPOR, karena itu kewajib
14	Rinaldi Syah Laki-Laki	Komputer i	2013	Bekerja	Sangat Siap	Sangat Relatif	Mer Pua	Mer Pua	Tidak ada, sudah udah sangat efisien
15	HTRAH	Komputer i	2020	Bekerja	Sangat Siap	Sangat Relatif	Mer Pua	Mer Pua	sangat bermanfaat, toki materi yg akan di hadapi di dunia pekerjaan

Gambar 2. Dataset file CSV Data\_Tesis\_Real.csv

#### 3.2 Distribusi Data

Hasil distribusi menunjukkan bahwa Program Studi Manajemen Perkantoran merupakan penyumbang terbesar responden dengan 392 alumni, mencerminkan fokus utama lembaga dalam bidang administrasi dan manajemen. Program Informatika Komputer dan Komputer Akuntansi menyusul dengan 230 dan 197 responden, menegaskan relevansi tinggi sektor teknologi informasi dan keuangan. Program Sekretaris mencatat 102 responden, menunjukkan peran sekretariat yang tetap dibutuhkan. Sementara itu, Program Digital Business Communication hanya diwakili 12 alumni, kemungkinan karena masih baru atau kurang diminati. Distribusi lengkap dapat dilihat pada grafik berikut.



Gambar 3. Grafik Distribusi Data

### 3.3 Hasil Preprocessing Data

*Preprocessing* data merupakan langkah awal yang sangat menentukan dalam keberhasilan analisis sentimen berbasis deep learning. Dalam konteks penelitian ini, data yang dianalisis merupakan tanggapan terbuka dari alumni terkait kesiapan mereka menghadapi dunia kerja serta sejauh mana kompetensi yang diperoleh selama studi di lembaga vokasi dirasakan relevan dengan tuntutan profesional. Fokus utama tertuju pada kolom *Gap Kompetensi*, yang merekam persepsi personal lulusan terhadap adanya ketidaksesuaian antara pembelajaran yang mereka terima dan realitas kebutuhan kerja. Proses ini tidak sekadar teknis, tetapi bersifat strategis: memastikan bahwa data yang masuk ke model Long Short-Term Memory (LSTM) adalah data yang bersih, konsisten, dan bermakna.[15]. Dengan demikian, model tidak hanya mempelajari pola teks, tetapi juga benar-benar menangkap makna emosional dan semantik yang terkandung dalam narasi responden. Melalui tahap ini, kualitas input ditingkatkan agar dapat menghasilkan output prediksi yang andal dan akurat dalam memetakan kesenjangan kompetensi vokasi. Adapun tahapan preprocessing yang diterapkan dalam penelitian ini akan diuraikan secara sistematis pada bagian berikutnya.

#### 3.3.1 Cleaning Teks

Proses *cleaning* teks ini bertujuan untuk menghilangkan elemen-elemen teks yang tidak relevan dan dapat mengganggu kinerja model dalam melakukan analisis sentimen. Langkah pertama yang dilakukan adalah mengubah seluruh teks menjadi huruf kecil (*lowercasing*) untuk menyamakan representasi kata dan menghindari redundansi akibat perbedaan kapitalisasi. Selanjutnya, dilakukan penghapusan tanda baca (*punctuation removal*), angka (*number removal*), dan karakter-karakter non-alfabetik lainnya yang tidak memberikan makna signifikan dalam analisis sentimen. Hasil dari proses ini bisa dilihat pada tabel dibawah ini.

Tabel 1. Tahap *Cleaning*

Teks Asli	Setelah Pembersihan
Jelas ada,karena apa yang di pelajari di Lp3i ...	jelas adakarena apa yang di pelajari di lp3i s...
menurut saya, utk pendalaman skill udah baik n...	menurut saya utk pendalaman skill udah baik na...

#### 3.3.2 Tokenizing

Tokenisasi merupakan proses memecah teks yang telah dibersihkan menjadi unit-unit kata atau token yang lebih kecil. Dalam konteks analisis sentimen dan pemodelan menggunakan Long Short Term Memory (LSTM), tokenisasi berfungsi untuk mengubah data teks tidak terstruktur menjadi representasi yang dapat diproses oleh model pembelajaran mesin, khususnya dalam bentuk urutan bilangan numerik. Hasil dari tahap ini bisa dilihat pada tabel berikut.

Tabel 2. Hasil Tokenizing

Cleaning Teks	Tokenizing
jelas ada karena apa yang di pelajari di lp3i s...	[jelas, ada, karena, apa, yang, di, pelajari, di...]
menurut saya utk pendalaman skill udah baik na...	[menurut, saya, utk, pendalaman, skill, udah, ...]

#### 3.3.3 Stemming

Tahap penting berikutnya dalam proses pra-pemrosesan teks adalah stemming, yaitu proses mengembalikan setiap kata pada data teks ke bentuk dasarnya atau bentuk kata dasar (root word). Tujuan utama dari stemming adalah untuk

menyederhanakan variasi kata yang memiliki akar makna yang sama, sehingga model tidak memperlakukan kata-kata tersebut sebagai entitas yang berbeda. Misalnya, kata “bekerja”, “berkerja”, dan “pekerjaan” semuanya akan dikembalikan ke bentuk dasar “kerja”. Dengan demikian, proses stemming membantu mengurangi dimensi fitur dan meningkatkan kemampuan model dalam mengenali pola sentimen dari kata-kata yang memiliki makna serupa. Penerapan *stemming* sangat penting dalam analisis sentimen karena membantu model untuk fokus pada makna inti dari setiap kata, tanpa terganggu oleh bentuk turunannya. Dengan menyatukan berbagai bentuk kata ke dalam satu representasi dasar, proses *stemming* tidak hanya menyederhanakan data, tetapi juga meningkatkan konsistensi input bagi model LSTM yang akan dilatih untuk mengklasifikasikan sentimen. Hasil dari tahap ini bisa dilihat pada tabel dibawah ini.

**Tabel 3.** Hasil *Stemming*

Tokenizing	Stemming
[jelas, ada, karena, apa, yang, di, pelajari, di...]	[jelas, ada, karena, apa, yang, di, ajar, di, ...]
[menurut, saya, utk, pendalaman, skill, udah, ...]	[turut, saya, utk, dalam, skill, udah, baik, n...]

### 3.3.4 Penggabungan Hasil *Stemming*

Setelah proses stemming dilakukan maka selanjutnya hasil stemming tersebut digabungkan kembali menjadi satu kalimat utuh. Tahap ini bukan hanya praktik teknis, tetapi juga strategi penting yang memungkinkan model Long Short-Term Memory (LSTM) membaca input sebagai urutan kata yang koheren.[16]. Bentuk kalimat utuh ini menjadi landasan dalam pelabelan sentimen—positif, negatif, atau netral—berdasarkan isi teks responden. Tanpa penggabungan ini, data cenderung terfragmentasi dan kehilangan konteks, sehingga model LSTM kesulitan menangkap makna yang sebenarnya.

**Tabel 4:** Penggabungan Teks Hasil *Stemming*

Stemming	Final Teks
[jelas, ada, karena, apa, yang, di, ajar, di, ...]	jelas ada karena apa yang di ajar di lp3i sang...
[turut, saya, utk, dalam, skill, udah, baik, n...]	turut saya utk dalam skill udah baik namun kes..

Tabel 4 menampilkan hasil akhir dari proses *preprocessing* data. Tahapan ini dilakukan agar data siap digunakan dalam proses tokenisasi dan padding sebelum dilatih menggunakan model. Penggabungan kata-kata hasil *stemming* menjadi kalimat utuh sangat penting, karena membantu model membaca dan memahami opini alumni sebagai satu kesatuan makna saat melakukan pelabelan sentimen.

Setelah melalui serangkaian proses *pre-processing*, data teks yang semula tidak terstruktur telah dibersihkan dan dinormalisasi, sehingga menjadi lebih siap untuk dianalisis pada tahap selanjutnya. Salah satu teknik visualisasi awal yang digunakan adalah *WordCloud*, yang mampu memberikan gambaran cepat mengenai kata-kata yang paling sering muncul dalam data teks. Visualisasi ini membantu dalam mengidentifikasi tema dominan serta potensi pola semantik yang muncul dari opini responden secara menyeluruh.[17]



**Gambar 3.** Perbandingan *WordCloud* sebelum dan sesudah *Preprocessing* Data

Gambar di atas membandingkan visualisasi *WordCloud* sebelum dan sesudah proses *preprocessing*. *WordCloud* kiri menunjukkan data mentah yang masih mengandung variasi bentuk kata, huruf kapital tidak seragam, serta frasa yang tidak terstruktur, sehingga kurang merepresentasikan tema utama secara jelas. Sebaliknya, *WordCloud* kanan menggambarkan hasil setelah dilakukan *cleaning text*, *Tokenizing* dan *stemming*, yang menghasilkan teks lebih bersih dan konsisten. Kata-kata kunci seperti "kerja", "dunia", "lp3i", dan "bantu" tampak lebih dominan, mencerminkan topik sentral terkait kesiapan kerja dan kesenjangan kompetensi. Hasil ini menegaskan bahwa *preprocessing* tidak hanya meningkatkan kualitas data, tetapi juga memperjelas pola sentimen dalam visualisasi teks.


### 3.4. Hasil Pelabelan Data Sentimen

Pelabelan data sentimen merupakan tahap krusial yang menentukan target pembelajaran model Long Short-Term Memory (LSTM). Dalam penelitian ini, pelabelan dilakukan secara otomatis menggunakan pendekatan rule-based berbasis lexicon lokal, yang disusun dari kata-kata bermuatan positif (misalnya: “kompeten”, “puas”, “siap”) dan negatif (misalnya: “kurang”, “tidak sesuai”, “mengecewakan”) sesuai konteks kesiapan kerja lulusan vokasi. Teks diklasifikasikan ke dalam tiga kategori sentimen: positif, negatif, dan netral, berdasarkan dominasi kata-kata tersebut. Pendekatan ini dipilih karena efisien untuk dataset besar dan mampu menghasilkan label yang konsisten.[18]. Hasil pelabelan data dapat dilihat pada tabel dibawah ini.

**Tabel 5.** Hasil pelabelan data

Teks	Nilai Label	Label Sentimen
jelas adakarena apa yang di pelajari di lp3i s...	2	Positif
menurut saya utk pendalaman skill udah baik na...	1	Negatif
tidak ada saya bisa menggunakan semua skill ya...	0	Netral
tidak ada guyss	0	Netral
kemampuan soft skill terutama komunikasi saya ...	1	Negatif

Berdasarkan hasil analisis sentimen terhadap data tanggapan alumni menggunakan pendekatan berbasis kata kunci (rule-based labeling), diperoleh distribusi sentimen sebagai berikut: sebanyak 506 data (atau sekitar 54,2%) dikategorikan sebagai positif, 251 data (sekitar 26,9%) sebagai netral, dan 177 data (sekitar 18,9%) tergolong dalam kategori negatif. Berikut bisa dilihat grafik distribusi sentiment.



**Gambar 4.** Perbandingan *WordCloud* sebelum dan sesudah Preprocessing Data

### 3.5 Hasil Tokenisasi dan Padding

Setelah preprocessing, data teks dikonversi ke format numerik melalui proses **tokenisasi**, yaitu pemecahan teks menjadi kata atau sub-kata yang kemudian direpresentasikan sebagai indeks numerik. Langkah ini memungkinkan model LSTM mengenali pola sekuensial dalam data. Selanjutnya, dilakukan **padding** untuk menyamakan panjang semua urutan dengan menambahkan token khusus (biasanya nol), sehingga input memiliki dimensi yang seragam. Kedua proses ini penting untuk memastikan data siap digunakan dalam tahap embedding dan pelatihan model secara efisien.[19]

#### 3.1.5 Hasil Tokenisasi

Proses tokenisasi dilakukan dengan menggunakan Tokenizer dari library Keras, yang bertugas mengonversi setiap kata dalam teks menjadi indeks angka berdasarkan frekuensi kemunculan dalam korpus. Misalnya, kata yang paling sering muncul akan diberi indeks yang lebih kecil. Tokenizer di-fit pada data hasil preprocessing akhir dan setiap kalimat dikonversi menjadi deretan angka (integer sequences) sesuai dengan kamus token yang terbentuk. Gambaran hasil tokenisasi bisa dilihat pada gambar 5 dibawah ini.

```
Teks Asli ke-1:
jelas ada karena apa yang di ajar di lp3i sangat bantu saat dunia kerja
Tokenisasi:
[293, 8, 56, 135, 2, 4, 10, 4, 7, 13, 24, 21, 9, 3]

Teks Asli ke-2:
turut saya utk dalam skill udah baik namun kesiap mental yg di aja kurang dan perlu di asah maksimal mungkin di lp3i
Tokenisasi:
[54, 5, 480, 11, 50, 481, 27, 41, 106, 482, 79, 4, 483, 51, 6, 38, 4, 111, 345, 187, 4, 7]

Teks Asli ke-3:
tidak ada saya bisa guna semua skill yang saya dapat di lp3i
Tokenisasi:
[12, 8, 5, 61, 39, 40, 50, 2, 5, 65, 4, 7]
```

**Gambar 5.** Hasil Tokenisasi

Dari hasil yang terlihat pada gambar 5 bahwa setiap kata dalam kalimat telah dikonversi ke token angka. Hal ini penting sebagai langkah awal sebelum melakukan proses padding dan pelatihan model Long Short-Term Memory (LSTM).

### 3.1.6 Hasil Padding

Setelah tokenisasi, langkah selanjutnya adalah **padding**, yaitu menyamakan panjang urutan token agar dapat diproses oleh model LSTM. Karena masing-masing kalimat menghasilkan deretan indeks dengan panjang berbeda, secara langsung memasukkannya ke LSTM akan menyebabkan error. Untuk itu, digunakan fungsi `pad_sequences` dari Keras untuk menambahkan nol (0) di awal atau akhir urutan hingga mencapai panjang maksimum yang ditentukan. Misalnya, jika `maxlen = 50`, maka kalimat yang kurang panjang akan diisi nol hingga mencapai panjang 50, sedangkan kalimat yang lebih panjang akan dipotong. Proses ini memastikan bahwa semua input memiliki dimensi tetap dan siap diolah dalam embedding maupun pelatihan model. Hasil Padding bisa dilihat pada gambar 6 dibawah ini.

```
Teks Asli:
jelas ada karena apa yang di ajar di lp3i sangat bantu saat dunia kerja

Tokenisasi:
[293, 8, 56, 135, 2, 4, 10, 4, 7, 13, 24, 21, 9, 3]

Padding:
[293  8  56 135  2  4  10  4  7  13  24  21  9  3  0  0  0  0
 0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0
 0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0
 0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0
 0  0  0  0  0]
```

**Gambar 6.** Hasil Padding

Pada gambar tersebut, dapat dilihat bahwa setelah padding, urutan token diubah menjadi array dua dimensi (matriks) dengan panjang yang seragam. Padding dilakukan dengan menambahkan angka 0 di akhir (karena parameter `padding='post'`) untuk melengkapi panjang kalimat yang kurang dari panjang maksimum.

### 3.6 Hasil Splitting Data

Setelah proses preprocessing selesai dilakukan, data yang telah melalui tahap tokenisasi dan padding kemudian dibagi menjadi dua bagian, yaitu data latih (training data) dan data uji (testing data). Proses ini bertujuan untuk memisahkan data yang akan digunakan untuk melatih model dan data yang akan digunakan untuk menguji performa model setelah proses pelatihan selesai. Pembagian dilakukan menggunakan fungsi `train_test_split` dari pustaka `scikit-learn` dengan rasio 80:20, artinya 80% dari total data digunakan sebagai data latih, sementara 20% sisanya digunakan sebagai data uji. Dari total 934 data yang tersedia, sebanyak 747 data digunakan sebagai data latih dan 187 data digunakan sebagai data uji.

```
from sklearn.model_selection import train_test_split

X_train, X_test, y_train, y_test = train_test_split(padded_sequences, df['label'], test_size=0.2, random_state=42)

print("Jumlah data latih (training):", len(X_train))
print("Jumlah data uji (testing):", len(X_test))

Jumlah data latih (training): 747
Jumlah data uji (testing): 187
```

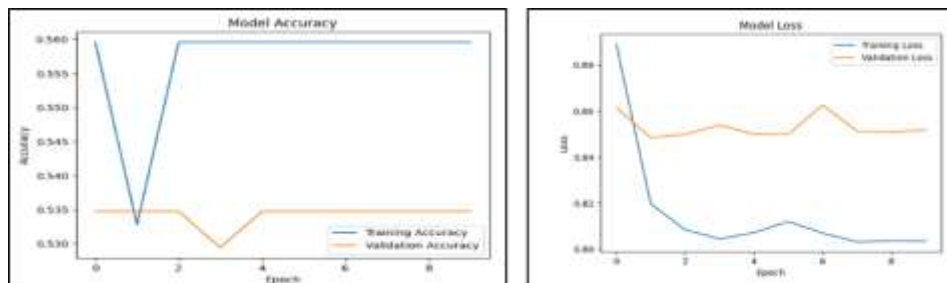
**Gambar 7.** Perintah program untuk Splitting Data

### 3.7 Hasil Pelatihan Model

Setelah preprocessing selesai, dilakukan pelatihan model LSTM dan BiLSTM dengan mempertimbangkan class weight untuk mengatasi ketidakseimbangan data kelas. Data tanggapan alumni (934 item: positif = 2, netral = 1, negatif = 0) terlebih dahulu melalui tahap tokenisasi dan padding (panjang maksimum 100 token), lalu dibagi 80 % data latih dan 20 % data uji. Tiga model yang dikembangkan menggunakan TensorFlow Keras: (1) LSTM baseline tanpa class weight, (2) LSTM dengan class weight, dan (3) BiLSTM. Pemberian class weight membantu menyeimbangkan kontribusi minoritas kelas negatif (hanya 33 data) selama pelatihan. Setiap model dilatih selama 10 epoch dengan batch size 32, dan metrik seperti akurasi dan loss dicatat untuk data latih dan validasi.[20]

#### 3.7.1 Model LSTM murni

Pelatihan dilakukan selama 10 epoch, dengan data latih sebanyak 80% dari total dataset dan 20% untuk data uji (validasi). Tujuan dari pelatihan ini adalah untuk mendapatkan baseline performa dari model sebelum dilakukan pendekatan penanganan ketidakseimbangan data atau perbaikan arsitektur lebih lanjut. Setiap epoch menghasilkan nilai metrik berupa *accuracy* dan *loss*, baik pada data pelatihan (*training*) maupun data validasi (*validation*). Hasil pelatihan selama 10 epoch ditampilkan melalui dua grafik utama yaitu Grafik Akurasi Model (Gambar 8) dan Grafik Loss Model (Gambar 7).



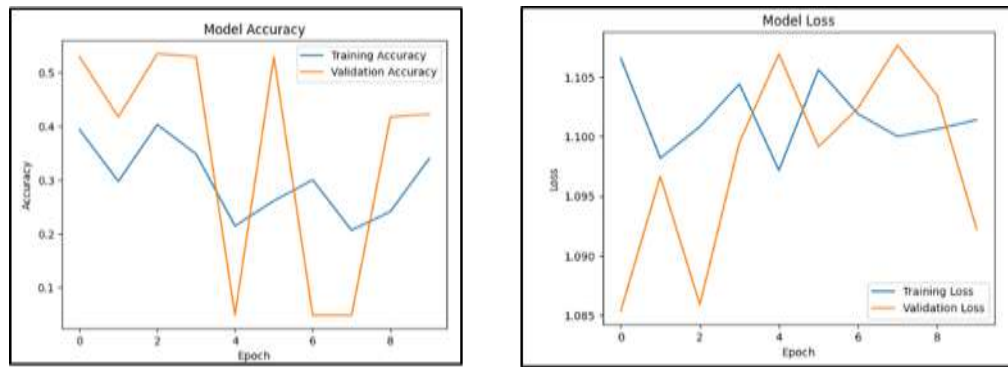
**Gambar 8.** Grafik Model Akurasi dan Grafik Loss Pelatihan dan Validasi Model LSTM murni

Gambar 8 menampilkan grafik *Model Accuracy* dan *Model Loss* selama proses pelatihan model LSTM baseline tanpa class weight selama 10 epoch. Grafik sebelah kiri menunjukkan bahwa akurasi pelatihan (biru) mengalami fluktuasi di awal epoch namun cenderung stabil di angka sekitar 0.56 setelah epoch ke-2. Sementara itu, akurasi validasi (orange) stagnan di angka sekitar 0.535, yang mengindikasikan tidak adanya peningkatan signifikan dalam kemampuan generalisasi model.

Pada grafik kanan, nilai *training loss* menunjukkan penurunan yang cukup konsisten hingga mencapai titik stabil di bawah 0.81, menandakan bahwa model mampu mempelajari pola dari data latih. Namun, *validation loss* tetap tinggi dan relatif konstan di sekitar 0.85, yang mengindikasikan kemungkinan **overfitting**, di mana model terlalu fokus pada data latih namun kurang mampu mengeneralisasi ke data uji.

#### 3.7.2 Model LSTM dengan class weight

Hasil pelatihan model setelah penerapan *class weight* pada 10 epoch menunjukkan bahwa model mengalami ketidakonsistenan dalam performa, khususnya pada akurasi dan *loss* validasi. Secara umum, nilai *accuracy* pada data pelatihan berkisar antara 19% hingga 39%, sedangkan *validation accuracy* bervariasi antara 4,8% hingga 53,4%. Rentang fluktuasi yang cukup besar pada akurasi validasi ini menunjukkan bahwa model masih mengalami kesulitan dalam melakukan generalisasi terhadap data uji. Hal ini tampak jelas pada epoch ke-5 hingga ke-8, di mana akurasi validasi menurun secara signifikan, bahkan mencapai titik terendah sebesar 4,8%, yang menunjukkan potensi masalah *overfitting* atau ketidakseimbangan representasi fitur antar kelas yang belum sepenuhnya teratasi meskipun telah digunakan *class weight*.




**Gambar 9.** Grafik Model Akurasi dan Garfik Loss Pelatihan dan Validasi Model LSTM dan Classweight. Gambar menunjukkan kurva *Model Accuracy* dan *Model Loss* dari pelatihan model LSTM dengan penerapan class weight selama 10 epoch. Grafik sebelah kiri memperlihatkan fluktuasi tajam pada akurasi pelatihan dan validasi. Akurasi pelatihan (garis biru) menunjukkan tren naik-turun tanpa pola konvergen yang jelas, dengan nilai tertinggi mendekati 0.35. Akurasi validasi (garis oranye) juga sangat tidak stabil, turun drastis hingga mendekati 0 pada beberapa epoch. Pola ini mengindikasikan bahwa model belum berhasil belajar secara konsisten dari data yang tidak seimbang, meskipun class weight telah diterapkan.

Sementara itu, grafik *Model Loss* di sebelah kanan menunjukkan bahwa nilai *training loss* dan *validation loss* tidak mengalami penurunan signifikan, dan cenderung fluktuatif sepanjang proses pelatihan. Hal ini menunjukkan bahwa model mengalami kesulitan dalam mencapai stabilitas pembelajaran dan kemungkinan belum menemukan parameter yang optimal dalam pelatihan.

### 3.7.3 Model Bidirectional LSTM (BiLSTM)

Hasil pelatihan model BiLSTM menunjukkan peningkatan kinerja yang signifikan dan stabil selama 10 epoch. Berdasarkan grafik akurasi, terjadi peningkatan bertahap baik pada data pelatihan (*training accuracy*) maupun data validasi (*validation accuracy*). Akurasi pelatihan meningkat dari 40,1% pada epoch pertama menjadi 98,0% pada epoch ke-10, sementara akurasi validasi naik dari 58,3% menjadi 90,3%. Hal ini mengindikasikan bahwa model mampu belajar representasi fitur dengan baik dan melakukan generalisasi secara efektif terhadap data validasi.



**Gambar 10.** Grafik Model Akurasi dan Garfik Loss Pelatihan dan Validasi Model BiLSTM

Gambar di atas menampilkan performa pelatihan model BiLSTM selama 10 epoch. Grafik kiri menunjukkan peningkatan konsisten pada *training accuracy* dan *validation accuracy*. Akurasi pelatihan meningkat dari sekitar 0.47 hingga mendekati 1.00, sedangkan akurasi validasi meningkat stabil hingga mencapai sekitar 0.92 pada epoch ke-8. Pola ini mencerminkan proses pembelajaran yang efektif dan kemampuan generalisasi model terhadap data uji.

Grafik kanan menunjukkan penurunan signifikan pada *training loss* dan *validation loss*, yang mengindikasikan bahwa model berhasil mengurangi kesalahan prediksi selama pelatihan. Kedua kurva loss menurun tajam dan stabil, menunjukkan tidak adanya indikasi overfitting. Secara keseluruhan, BiLSTM menunjukkan performa pelatihan dan validasi yang optimal dibandingkan model sebelumnya.

### 3.8 Hasil Evaluasi Model

Evaluasi model dilakukan untuk mengevaluasi efektivitas dan performa model dalam mengklasifikasikan sentimen alumni terhadap kesesuaian kompetensi lulusan lembaga pendidikan vokasi dengan kebutuhan dunia kerja. Dalam penelitian ini, digunakan beberapa arsitektur model berbasis *deep learning*, yaitu LSTM murni, LSTM dengan *class weights*, dan BiLSTM. Evaluasi dilakukan menggunakan metrik umum dalam klasifikasi multi-kelas, yaitu *accuracy*, *precision*, *recall*, dan *f1-score*, baik secara per kelas, rata-rata makro (*macro average*), maupun rata-rata berbobot (*weighted average*).

Untuk mendapatkan gambaran yang lebih jelas mengenai efektivitas masing-masing model yang digunakan dalam penelitian ini, dilakukan perbandingan performa antara tiga model utama, yaitu LSTM murni, LSTM dengan class weights, dan BiLSTM. Perbandingan ini dilakukan dengan menggunakan metrik evaluasi yang meliputi akurasi, precision, recall, dan f1-score, baik secara makro, berbobot (*weighted*), maupun per kelas. Ringkasan hasil evaluasi dari ketiga model bisa dilihat pada Tabel 6 dibawah ini.

**Tabel 6.** Perbandingan *Classification report* 3 Model LSTM

Metrik Evaluasi	LSTM Murni	LSTM + Class Weights	BiLSTM
Akurasi	0.42	0.42	0.90
Precision (Macro)	0.18	0.47	0.80
Recall (Macro)	0.33	0.34	0.80
F1-Score (Macro)	0.23	0.20	0.80
F1-Score (Weighted)	0.26	0.26	0.91
F1-Score Kelas Positif	0.00	0.02	0.95
F1-Score Kelas Netral	0.59	0.59	0.89
F1-Score Kelas Negatif	0.00	0.00	0.56

Berdasarkan hasil perbandingan performa model dalam Tabel 9, dapat disimpulkan bahwa arsitektur BiLSTM memberikan hasil terbaik dalam mengklasifikasikan sentimen tanggapan alumni. BiLSTM secara konsisten menghasilkan nilai evaluasi tertinggi pada seluruh metrik, baik akurasi, f1-score makro, maupun f1-score berbobot. Khususnya, model ini menunjukkan kemampuan yang sangat baik dalam mengenali sentimen positif dan netral dengan f1-score masing-masing sebesar 0.95 dan 0.89. Sementara itu, performa model LSTM murni dan LSTM dengan class weights masih terbatas, terutama dalam mengenali kelas negatif dan positif secara akurat. Oleh karena itu, BiLSTM terbukti menjadi pilihan model yang paling efektif untuk diterapkan dalam analisis sentimen terhadap kesesuaian kompetensi lulusan lembaga pendidikan vokasi dengan kebutuhan dunia kerja.

#### 4. KESIMPULAN

Penelitian ini menunjukkan bahwa model LSTM, khususnya BiLSTM, efektif dalam mengklasifikasikan sentimen alumni terhadap kompetensi lulusan LP3I Banda Aceh. BiLSTM mencatat akurasi tertinggi (90%) dan weighted F1-score sebesar 0.91, unggul dalam menangkap konteks dua arah teks. Penerapan class weight juga terbukti meningkatkan performa model terhadap kelas minoritas. Analisis sentimen mengungkap bahwa sekitar 44,5% tanggapan bernada netral dan negatif, mencerminkan adanya gap kompetensi antara pembelajaran di kampus dan tuntutan dunia kerja, baik dari sisi hard skill maupun soft skill. Temuan ini menekankan pentingnya evaluasi kurikulum dan kolaborasi industri untuk meningkatkan kesiapan kerja lulusan. Secara keseluruhan, pendekatan deep learning berbasis LSTM terbukti mampu menyediakan evaluasi data-driven yang efisien dan akurat dalam memetakan persepsi lulusan terhadap kualitas pendidikan vokasi.

#### DAFTAR PUSTAKA

- [1] Muhammad Haris Diponegoro, Sri Suning Kusumawardani, and Indriana Hidayah, "Tinjauan Pustaka Sistematis: Implementasi Metode Deep Learning pada Prediksi Kinerja Murid," *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 10, no. 2, pp. 131–138, 2021, doi: 10.22146/jnteti.v10i2.1417.
- [2] S. Mutmatimah, Khairunnas, and Khairunnisa, "Metode Deep Learning LSTM dalam Analisis Sentimen Aplikasi PeduliLindungi," *J. Comput. Sci. Informatics*, vol. 1, no. 1, pp. 9–19, 2024, doi: 10.34304/scientific.v1i1.231.
- [3] L. G. Astuti, P. S. Informatika, and U. Udayana, "Implementasi LSTM pada Analisis Sentimen Review Film," *J. Elektron. Ilmu Komput. Udayana*, vol. 10, no. 4, pp. 351–362, 2022.
- [4] A. A. Mudding and Arifin A Abd Karim, "Analisis Sentimen Menggunakan Algoritma Lstm Pada Media Sosial," *J. Publ. Ilmu Komput. dan Multimed.*, vol. 1, no. 3, pp. 181–187, 2022, doi: 10.55606/jupikom.v1i3.517.
- [5] A. Rolangon, A. Weku, and G. A. Sandag, "Perbandingan Algoritma LSTM Untuk Analisis Sentimen Pengguna Twitter Terhadap Layanan Rumah Sakit Saat Pandemi Covid-19," *TeIka*, vol. 13, no. 01, pp. 31–40, 2023, doi: 10.36342/teika.v13i01.3063.
- [6] A. R. Isnain, H. Sulistiani, B. M. Hurohman, A. Nurkholis, and S. Styawati, "Analisis Perbandingan Algoritma LSTM dan Naive Bayes untuk Analisis Sentimen," *J. Edukasi dan Penelit. Inform.*, vol. 8, no. 2, p. 299, 2022, doi: 10.26418/jp.v8i2.54704.
- [7] M. F. Naufal and S. F. Kusuma, "Analisis Sentimen pada Media Sosial Twitter Terhadap Kebijakan Pemberlakuan Pembatasan Kegiatan Masyarakat Berbasis Deep Learning," *J. Edukasi dan Penelit. Inform.*, vol.



- 8, no. 1, p. 44, 2022, doi: 10.26418/jp.v8i1.49951.
- [8] S. Aripriyanto, T. Tukino, A. Sufyan, and R. Nandaputra, "Sentimen Analisis Twitter Ibu Kota Negara Nusantara Menggunakan Long Short-Term Memory dan Lexicon Based," *Expert J. Manaj. Sist. Inf. dan Teknol.*, vol. 12, no. 2, p. 119, 2022, doi: 10.36448/expert.v12i2.2821.
- [9] Y. N. AS, D. I. Mulyana, and Y. Akbar, "Klasifikasi Rumput Liar Menggunakan Deep Learning Dengan Dense Convolutional Neural Network," *Progresif J. Ilm. ...*, pp. 347–358, 2023, [Online]. Available: <http://ojs.stmik-banjarbaru.ac.id/index.php/progresif/article/view/1166%0Ahttp://ojs.stmik-banjarbaru.ac.id/index.php/progresif/article/download/1166/675>
- [10] D. R. Alghifari, M. Edi, and L. Firmansyah, "Implementasi Bidirectional LSTM untuk Analisis Sentimen Terhadap Layanan Grab Indonesia," *J. Manaj. Inform.*, vol. 12, no. 2, pp. 89–99, 2022, doi: 10.34010/jamika.v12i2.7764.
- [11] S. Nurmani, A. Darmawahyuni, A. I. Sapitri, M. N. Rachmatullah, Firdaus, and B. Tutuko, "Pengenalan Deep Learning dan Implementasinya," p. 137, 2021.
- [12] F. Fitroh and F. Hudaya, "Systematic Literature Review: Analisis Sentimen Berbasis Deep Learning," *J. Nas. Teknol. dan Sist. Inf.*, vol. 9, no. 2, pp. 132–140, 2023, doi: 10.25077/teknosi.v9i2.2023.132-140.
- [13] B. Raharjo, *Deep Learning dengan Python*. 2022.
- [14] S. S. Roy, A. I. Awad, L. A. Amare, M. T. Erkihun, and M. Anas, "Multimodel Phishing URL Detection Using LSTM, Bidirectional LSTM, and GRU Models," *Futur. Internet*, vol. 14, no. 11, 2022, doi: 10.3390/fi14110340.
- [15] A. Santosa, I. Purnamasari, and Mayasari Rini, "Pengaruh Stopword Removal dan Stemming Terhadap Performa Klasifikasi Teks Komentar Kebijakan New Normal Menggunakan Algoritma LSTM," *J. Sains Komput. Inform.*, vol. 6, pp. 81–93, 2022.
- [16] K. Alahmadi, S. Alharbi, J. Chen, and X. Wang, "Generalizing sentiment analysis: a review of progress, challenges, and emerging directions," *Soc. Netw. Anal. Min.*, vol. 15, no. 1, 2025, doi: 10.1007/s13278-025-01461-8.
- [17] I. T. Julianto, "Analisis Sentimen Terhadap Sistem Informasi Akademik Institut Teknologi Garut," *J. Algoritm.*, vol. 19, no. 1, pp. 449–456, 2022, doi: 10.33364/algoritma/v.19-1.1112.
- [18] R. Refianti, A. B. Mutiara, and R. A. Putra, "A Lexicon-Based Long Short-Term Memory (LSTM) Model for Sentiment Analysis to Classify Halodoc Application Reviews on Google Playstore," *J. Appl. Data Sci.*, vol. 5, no. 1, pp. 146–157, 2024, doi: 10.47738/jads.v5i1.160.
- [19] R. Sood, "Sentiment analysis using LSTM models | NLP," no. 12, pp. 2654–2660, 2024.
- [20] A. P. Wibawa, D. E. Cahyani, D. D. Prasetya, L. Gumilar, and A. Nafalski, "Detecting emotions using a combination of bidirectional encoder representations from transformers embedding and bidirectional long short-term memory," *Int. J. Electr. Comput. Eng.*, vol. 13, no. 6, pp. 7137–7146, 2023, doi: 10.11591/ijece.v13i6.pp7137-7146.

