

Komparasi *Machine Learning* dalam Analisis Sentimen Berbasis Aspek dan Deteksi Emosi pada Ulasan Aplikasi Lowongan Kerja

Hana Husna Safitri¹⁾, Viktor Handrianus Pranatawijaya²⁾, Ressa Priskila³⁾

¹⁾²⁾³⁾Jurusan Teknik Informatika, Fakultas Teknik, Universitas Palangka Raya
Kampus Tanjung Nyaho, Jl. Yos Sudarso, Palangka Raya

¹⁾hanasafitri2002@gmail.com

²⁾viktorhp@it.upr.ac.id

³⁾ressa@it.upr.ac.id

Abstrak

Seiring meningkatnya penggunaan aplikasi pencari kerja, ulasan pengguna di *platform digital* menjadi sumber penting untuk mengevaluasi kualitas layanan. Namun, ulasan tersebut sering kali tidak terstruktur dan mengandung ekspresi kompleks. Penelitian ini menerapkan teknik *machine learning* untuk mengidentifikasi aspek dominan, serta memahami sentimen dan emosi dalam ulasan aplikasi Glints dan Jobstreet dari Google Play Store. Tiga model dibandingkan, yaitu *Support Vector Machine (SVM)*, *Random Forest*, dan *Multinomial Logistic Regression*. Data diperoleh melalui *scraping*, diproses dengan tahapan *preprocessing*, dan dianotasi menggunakan LDA dan *Generative AI* untuk aspek, *IndoBERT* untuk sentimen, serta *NRC Emotion Lexicon* untuk emosi. *Dataset* dibagi dalam rasio 80:20 dan 90:10. Hasil menunjukkan bahwa model terbaik untuk klasifikasi aspek adalah SVM (*split* 90:10) dengan akurasi 97,67%, untuk sentimen adalah *Multinomial Logistic Regression* (*split* 90:10) dengan akurasi 94,49%, dan untuk emosi adalah SVM (*split* 90:10) dengan akurasi 99,46%. Aspek yang paling dominan adalah Pencarian Kerja, diikuti Pengalaman Pengguna. Sentimen ulasan didominasi oleh sentimen positif, dan emosi yang paling sering muncul adalah bahagia. Penelitian ini membantu mengevaluasi kinerja model dan memahami persepsi pengguna terhadap aplikasi pencari kerja.

Kata kunci: *Machine Learning*, Aplikasi Pencari Kerja, Aspek, Sentimen, Emosi

Abstract

As the use of job search apps increases, user reviews on digital platforms have become an important source for evaluating service quality. However, these reviews are often unstructured and contain complex expressions. This study applies machine learning techniques to identify dominant aspects and understand sentiment and emotion in reviews of the Glints and Jobstreet apps from the Google Play Store. Three models were compared: Support Vector Machine (SVM), Random Forest, and Multinomial Logistic Regression. Data was obtained through scraping, processed through preprocessing stages, and annotated using LDA and Generative AI for aspects, IndoBERT for sentiment, and the NRC Emotion Lexicon for emotions. The dataset was divided in an 80:20 and 90:10 ratio. The results show that the best model for aspect classification is SVM (*split* 90:10) with an accuracy of 97.67%, for sentiment is Multinomial Logistic Regression (*split* 90:10) with an accuracy of 94.49%, and for emotion is SVM (*split* 90:10) with an accuracy of 99.46%. The most dominant aspect is Job Search, followed by User Experience. Review sentiment is dominated by positive sentiment, and the most frequently occurring emotion is happiness. This study helps evaluate model performance and understand user perceptions of job search applications.

Keywords: *Machine Learning*, Job Seekers Application, Aspect, Sentiment, Emotion

1. PENDAHULUAN

Mendapatkan pekerjaan yang sesuai merupakan impian banyak pencari kerja. Namun, di Indonesia, proses ini masih menghadapi berbagai tantangan, seperti tingginya tingkat persaingan dan terbatasnya akses terhadap informasi lowongan kerja. Survei Populix menunjukkan bahwa 69% Gen Z di Indonesia mengalami kesulitan dalam mencari pekerjaan [1]. Data Badan Pusat Statistik (BPS) juga mencatat bahwa pada Agustus 2024 terdapat 7.465.599 pengangguran, dengan 11,28% atau sekitar 842.378 di antaranya merupakan lulusan perguruan tinggi [2]. Di era digital, aplikasi pencari kerja seperti Glints dan Jobstreet telah menjadi alternatif populer. Keduanya masuk dalam sepuluh besar aplikasi bisnis terpopuler di Google Play Store pada Maret 2025. Banyaknya ulasan pengguna di platform tersebut menunjukkan pentingnya ulasan sebagai sumber informasi dalam mengevaluasi kualitas aplikasi [3]. Namun, ulasan di Google Play Store sering kali tidak terstruktur dan mengandung ekspresi yang kompleks. Dalam beberapa kasus, terjadi ketidaksesuaian antara rating dan isi ulasan [4].

Analisis sentimen dan emosi menjadi penting untuk memahami persepsi pengguna secara lebih sistematis [5]. Sayangnya, masih terdapat kesenjangan dalam pendekatan analisis sentimen berbasis aspek yang mampu menangkap konteks ulasan secara menyeluruh. Oleh karena itu, penelitian ini membandingkan tiga model machine learning, yaitu Support Vector Machine (SVM), Random Forest, dan Multinomial Logistic Regression, untuk mengidentifikasi model terbaik dalam klasifikasi aspek, sentimen, dan emosi pada ulasan aplikasi Glints dan Jobstreet. SVM dikenal unggul dalam klasifikasi teks, meskipun sensitif terhadap fitur yang kurang relevan [6]. Random Forest efektif menangani data non-linear dan mampu mengurangi overfitting [7]. Sementara itu, Multinomial Logistic Regression cocok digunakan untuk klasifikasi multikelas dan data non-linier [8]. Dengan pendekatan ini, penelitian diharapkan dapat memberikan kontribusi terhadap pengembangan metode analisis sentimen yang lebih efektif dan akurat dalam konteks aplikasi pencari kerja.

2. TINJAUAN PUSTAKA

2.1 Analisis Sentimen Berbasis Aspek

Analisis sentimen berbasis aspek atau *Aspect-based Sentiment Analysis* (ABSA) adalah tugas dan teknik tingkat lanjut yang dikembangkan berdasarkan analisis sentimen. Analisis sentimen berbasis aspek adalah teknik analisis teks yang mengkategorikan data berdasarkan aspek dan mengidentifikasi sentimen yang dikaitkan dengan masing-masing aspek [9].

2.2 Deteksi Emosi

Deteksi emosi adalah proses analisis sentimen yang digunakan untuk mengekstrak emosi dari teks yang paling mewakili kondisi mental penulis. Dalam beberapa tahun terakhir, domain pendeteksian emosi telah menjadi sangat populer karena potensi aplikasinya dalam kecerdasan buatan, interaksi manusia komputer, psikologi, dan pemasaran [10].

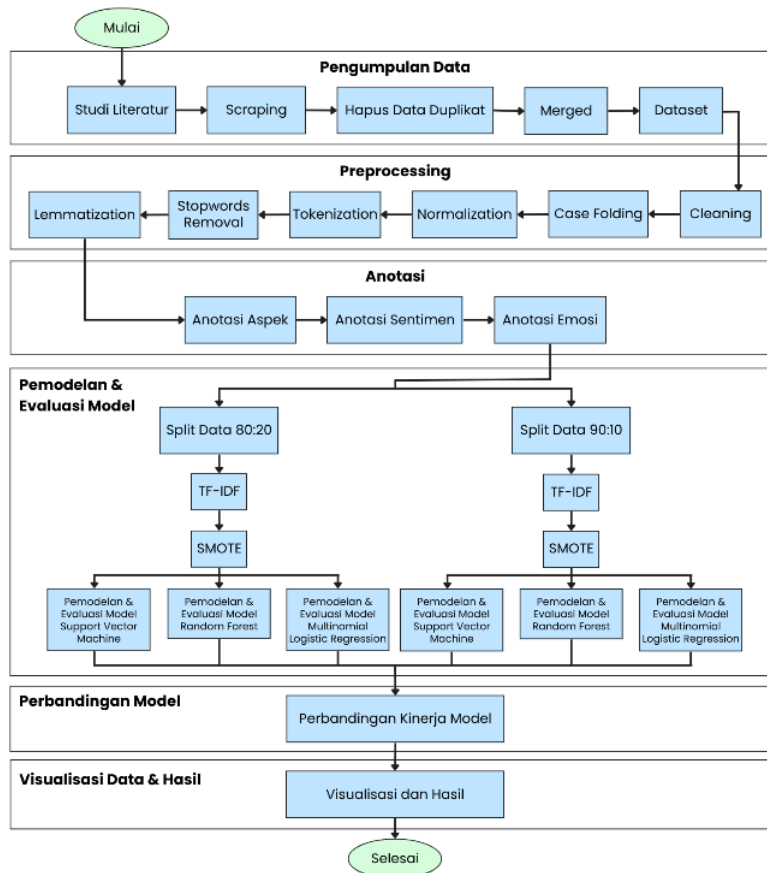
2.3 Machine Learning

Machine learning adalah sebuah pendekatan kecerdasan buatan (AI) di mana mesin dapat secara otomatis belajar dan meningkatkan kinerjanya berdasarkan pengalaman. Hal ini tidak diprogram secara eksplisit; data dimasukkan ke dalam algoritma umum dan membangun logika berdasarkan data yang disediakan. Algoritma *machine learning* mempelajari pola *input* baru yang mampu menangani situasi yang kompleks dengan tetap menjaga akurasi dan efisiensi. Karena manfaatnya yang nyata, algoritma *machine learning* digunakan di berbagai domain seperti perawatan kesehatan, industri, travel, pengembangan *game*, layanan media sosial, robotika, serta pengawasan dan keamanan informasi [11].

2.4 Text Preprocessing

Text preprocessing adalah langkah mendasar dalam menyiapkan data teks mentah untuk analisis dan pemodelan dalam berbagai tugas pemrosesan bahasa alami (NLP). Proses ini melibatkan serangkaian teknik yang bertujuan untuk *cleaning*, *transforming*, dan *organizing* data teks untuk meningkatkan kualitasnya dan membuatnya sesuai untuk pemrosesan lebih lanjut [12].

3. METODE PENELITIAN



Gambar 1. Metodologi penelitian

Penelitian ini dimulai dengan pengumpulan data, dilanjutkan tahap *preprocessing*, anotasi aspek, sentimen, dan emosi. Data kemudian dibagi dengan rasio 80:20 dan 90:10, diekstraksi menggunakan TF-IDF, serta diseimbangkan menggunakan SMOTE. Selanjutnya dilakukan pemodelan dan evaluasi menggunakan *Support Vector Machine* (SVM), *Random Forest*, dan *Multinomial Logistic Regression*. Hasil evaluasi dibandingkan, lalu divisualisasikan sebagai *output* akhir.

4. PEMBAHASAN

4.1 Pengumpulan Data

Data dikumpulkan melalui *web scraping* ulasan berbahasa Indonesia dari aplikasi Jobstreet dan Glints di Google Play Store menggunakan Google Play Scraper. Setelah menghapus duplikat dan *spam*, diperoleh 26.345 ulasan untuk analisis.

Tabel 1. *Dataset* ulasan aplikasi lowongan kerja

| Aplikasi | Tanggal | Ulasan |
|-----------|---------------|--|
| Jobstreet | 07 Maret 2025 | praktis, selalu ada selama 24 jam/hari |
| Jobstreet | 07 Maret 2025 | Bagus |
| Glints | 07 Maret 2025 | Oke bagus banget |
| Glints | 07 Maret 2025 | sangat membantu |

4.2 *Preprocessing*

4.2.1 *Cleaning*

Pada tahap *cleaning*, teks ulasan dibersihkan dari elemen tidak relevan seperti URL, *mention*, *hashtag*, emoji, angka, tanggal, waktu, karakter *non-huruf*, dan spasi berlebih.

Tabel 2. Hasil *cleaning*

| Sebelum Cleaning | Sesudah Cleaning |
|--|--|
| praktis, selalu ada selama 24 jam/hari Oke bagus banget | praktis selalu ada selama jam hari Oke bagus banget |

4.2.2 Case Folding

Pada tahap *case folding*, seluruh teks diubah menjadi huruf kecil untuk menyamakan bentuk kata yang serupa.

Tabel 3. Hasil *case folding*

| Sebelum Case Folding | Sesudah Case Folding |
|--|--|
| praktis selalu ada selama jam hari Oke bagus banget | praktis selalu ada selama jam hari oke bagus banget |

4.2.3 Normalization

Pada tahap normalisasi, kata tidak baku dan singkatan diubah ke bentuk baku menggunakan kamus, agar konsisten dan mudah dianalisis.

Tabel 4. Hasil *normalization*

| Sebelum Normalization | Sesudah Normalization |
|--|---|
| praktis selalu ada selama jam hari oke bagus banget | praktis selalu ada selama jam hari baik bagus banget |

4.2.4 Tokenization

Pada tahap tokenisasi, teks dipecah menjadi kata-kata (*token*) menggunakan model spaCy multibahasa agar mempermudah pemrosesan dan analisis lanjutan.

Tabel 5. Hasil *tokenization*

| Sebelum Tokenization | Sesudah Tokenization |
|---|--|
| praktis selalu ada selama jam hari baik bagus banget | ['praktis', 'selalu', 'ada', 'selama', 'jam', 'hari'] ['baik', 'bagus', 'banget'] |

4.2.5 Stopwords Removal

Pada tahap *stopwords removal*, kata-kata umum yang tidak bermakna signifikan dihapus menggunakan daftar *stopwords* NLTK Bahasa Indonesia, kecuali kata negasi agar makna ulasan tetap terjaga.

Tabel 6. Hasil *stopwords removal*

| Sebelum Stopwords Removal | Sesudah Stopwords Removal |
|--|---|
| ['praktis', 'selalu', 'ada', 'selama', 'jam', 'hari'] ['baik', 'bagus', 'banget'] | ['praktis', 'jam', 'hari'] ['bagus'] |

4.2.6 Lemmatization

Pada tahap *lemmatization*, kata-kata diubah ke bentuk dasar menggunakan *library* Stanza yang mendukung Bahasa Indonesia. Proses ini menghasilkan teks dengan kata dasar yang lebih alami dan siap untuk analisis lanjutan.

Tabel 7. Hasil *lemmatization*

| Sebelum Lemmatization | Sesudah Lemmatization |
|---|---------------------------|
| ['praktis', 'jam', 'hari'] ['bagus'] | praktis jam hari bagus |

4.3 Anotasi Aspek

4.3.1 Bag of Words


Bag of Words mengubah ulasan menjadi format numerik (kata_id, frekuensi) dengan Gensim agar dapat diolah oleh model.

4.3.2 Pemodelan Latent Dirichlet Allocation (LDA)

Pemodelan Latent Dirichlet Allocation (LDA) digunakan untuk menemukan topik dominan dalam ulasan. Jumlah topik optimal dipilih berdasarkan nilai coherence tertinggi, yaitu 2 topik, yang kemudian digunakan untuk anotasi aspek. Nilai coherence dari setiap model juga diplot untuk analisis visual.

Tabel 8. Nilai koherensi

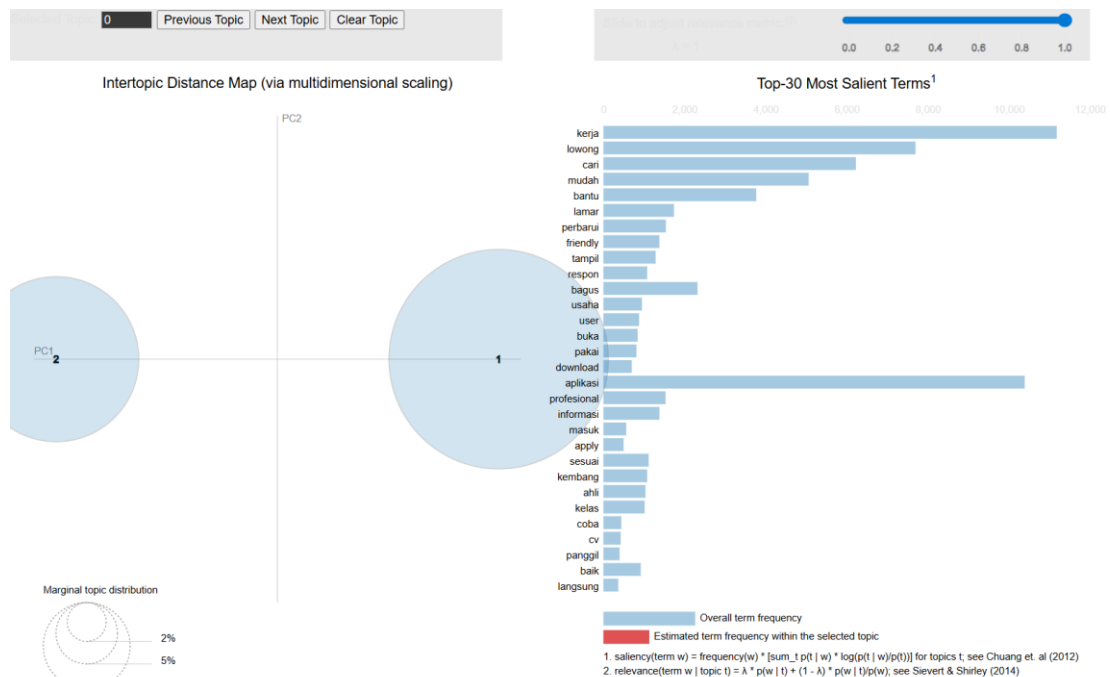
| Num Topics | Coherence Value |
|------------|-----------------|
| 2 | 0,457 |
| 3 | 0,394 |
| 4 | 0,365 |



Gambar 2. Grafik nilai koherensi

4.3.3 Identifikasi dan Interpretasi Topik Ulasan

Setelah model LDA terbaik diperoleh, topik divisualisasikan untuk melihat proporsi dan perbedaannya. Kata kunci teratas dari tiap topik dicetak dan disimpan dalam kamus topik-kata kunci. Selanjutnya, setiap ulasan dikaitkan dengan topik dominan berdasarkan kontribusi terbesar dari hasil LDA.



Gambar 3. Visualisasi hasil model LDA

Setelah topik dianalisis menggunakan *Generative AI* dari Google Gemini dan didapat dua aspek utama, yaitu Pencarian Kerja dan Pengalaman Pengguna, setiap topik kemudian dipetakan ke aspek yang relevan melalui *dictionary* bernama *aspect_mapping*. Dengan pemetaan ini, setiap ulasan memiliki aspek dominan yang merepresentasikan isi ulasannya.

Tabel 9. Nilai koherensi

| Topik | Kata Kunci Topik | Aspek |
|-------|---|---------------------|
| 1 | kerja, aplikasi, lowongan, cari, mudah, bantu, bagus, fitur, profesional, informasi, lengkap, sesuai, kembang, ahli, kelas | Pencarian Kerja |
| 2 | lamar, perbarui, <i>friendly</i> , aplikasi, tampil, respon, usaha, <i>user</i> , buka, pakai, <i>download</i> , masuk, <i>apply</i> , coba, cv | Pengalaman Pengguna |

Tabel 10. Hasil anotasi aspek

| Perc_Contrib | Ulasan | Aspek |
|-------------------|-------------------------------------|---------------------|
| 0,53700000476837 | praktis jam hari | Pengalaman Pengguna |
| 0,832000017166138 | bagus | Pencarian Kerja |
| 0,806999981403351 | perbarui susah hubung tim rekrutmen | Pengalaman Pengguna |

4.4 Anotasi Sentimen

Pada tahap anotasi sentimen, ulasan yang telah diberi anotasi aspek diklasifikasikan menggunakan model *IndoBERT* berbahasa Indonesia. Model ini memproses teks melalui tokenisasi dan menghasilkan prediksi sentimen positif atau negatif beserta skor probabilitas tertingginya menggunakan fungsi *get_sentiment_indobert*.

Tabel 11. Hasil anotasi sentimen

| Ulasan | Sentimen | Score |
|-------------------------------------|----------|-------------|
| praktis jam hari | Positif | 0,993546665 |
| bagus | Positif | 0,998813987 |
| perbarui susah hubung tim rekrutmen | Negatif | 0,999172211 |

4.5 Anotasi Emosi

Pada tahap anotasi emosi, setiap ulasan dianalisis menggunakan kamus NRC *Lexicon* Bahasa Indonesia untuk mengidentifikasi lima emosi: *joy*, *trust*, *sadness*, *fear*, dan *anger*. Emosi dikategorikan menjadi positif (*joy*, *trust*) dan negatif (*anger*, *fear*, *sadness*). Skor emosi dihitung dari frekuensi kata terkait, lalu ditentukan emosi dominan berdasarkan skor tertinggi dan urutan prioritas. Setiap emosi dipetakan ke dimensi *valence* dan *arousal* untuk analisis lanjutan.

Tabel 12. Hasil anotasi emosi

| Ulasan | Emosi | Valence | Arousal |
|-------------------------------------|--------------|-----------------|-------------|
| praktis jam hari | <i>joy</i> | <i>Positive</i> | <i>High</i> |
| bagus | <i>joy</i> | <i>Positive</i> | <i>High</i> |
| perbarui susah hubung tim rekrutmen | <i>anger</i> | <i>Negative</i> | <i>High</i> |

4.6 Pemodelan dan Evaluasi Model

Data dibagi dalam dua skenario rasio, yaitu 80:20 dan 90:10 untuk pelatihan dan pengujian model SVM, *Random Forest*, dan *Multinomial Logistic Regression*. Teks ulasan dikonversi ke format numerik menggunakan TF-IDF, yang membantu model fokus pada kata-kata penting dengan mengurangi pengaruh kata umum. Untuk mengatasi ketidakseimbangan label, digunakan metode SMOTE pada data latih guna menghasilkan data sintesis pada kelas minoritas. SMOTE diterapkan untuk ketiga kategori anotasi (aspek, sentimen, dan emosi) agar distribusi label lebih seimbang dan performa model meningkat.

4.6.1 Pemodelan dan Evaluasi Model untuk Klasifikasi Aspek

Pemodelan klasifikasi aspek dilakukan menggunakan SVM, *Random Forest*, dan *Multinomial Logistic Regression* dengan skenario *split* data 80:20 dan 90:10. Kinerja model dievaluasi menggunakan metrik akurasi, presisi, *recall*, *f1-score*.

Tabel 13. Hasil evaluasi model untuk aspek

| Split Data | Metrik | Model | | |
|------------|-----------|------------------------|---------------|---------------------------------|
| | | Support Vector Machine | Random Forest | Multinomial Logistic Regression |
| 80:20 | Accuracy | 97,56% | 96,51% | 97,15% |
| | Precision | 97,64% | 96,52% | 97,28% |
| | Recall | 97,56% | 96,51% | 97,15% |
| | F1-Score | 97,58% | 96,51% | 97,18% |
| 90:10 | Accuracy | 97,67% | 96,62% | 97,36% |
| | Precision | 97,75% | 96,66% | 97,48% |
| | Recall | 97,67% | 96,62% | 97,36% |
| | F1-Score | 97,69% | 96,64% | 97,39% |

4.6.2 Pemodelan dan Evaluasi Model untuk Klasifikasi Sentimen

Pemodelan klasifikasi sentimen dilakukan dengan model dan skenario *split* data yang sama serta menggunakan metrik evaluasi yang serupa untuk menilai performa masing-masing model.

Tabel 14. Hasil evaluasi model untuk sentimen

| Split Data | Metrik | Model | | |
|------------|-----------|------------------------|---------------|---------------------------------|
| | | Support Vector Machine | Random Forest | Multinomial Logistic Regression |
| 80:20 | Accuracy | 93,89% | 93,89% | 94,45% |
| | Precision | 94,32% | 94,43% | 94,82% |
| | Recall | 93,89% | 93,89% | 94,45% |
| | F1-Score | 94% | 94,02% | 94,55% |
| 90:10 | Accuracy | 94,14% | 93,95% | 94,49% |
| | Precision | 94,60% | 94,44% | 94,98% |
| | Recall | 94,14% | 93,95% | 94,49% |
| | F1-Score | 94,25% | 94,07% | 94,60% |

4.6.3 Pemodelan dan Evaluasi Model untuk Klasifikasi Emosi

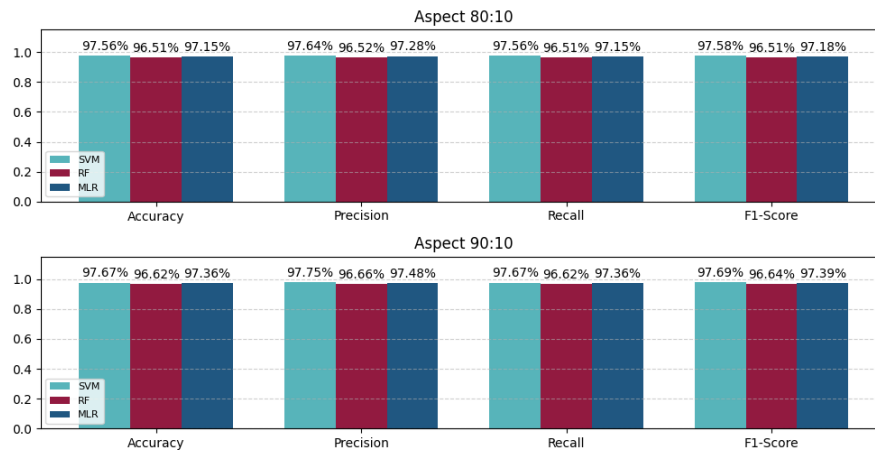
Pemodelan klasifikasi emosi dilakukan dengan model dan skenario *split* data yang sama serta menggunakan metrik evaluasi yang serupa untuk menilai performa masing-masing model.

Tabel 15. Hasil evaluasi model untuk emosi

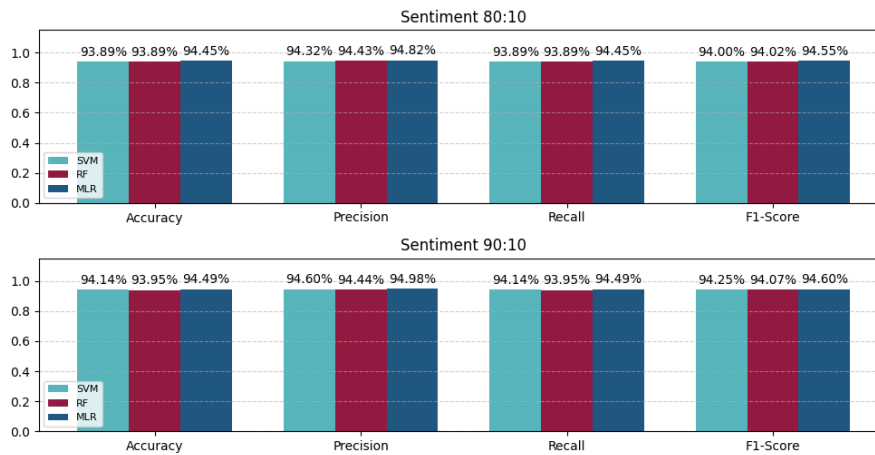
| Split Data | Metrik | Model | | |
|------------|-----------|------------------------|---------------|---------------------------------|
| | | Support Vector Machine | Random Forest | Multinomial Logistic Regression |
| 80:20 | Accuracy | 99,19% | 97,23% | 98,82% |
| | Precision | 99,19% | 97,22% | 98,82% |
| | Recall | 99,19% | 97,23% | 98,82% |
| | F1-Score | 99,15% | 97,10% | 98,81% |
| 90:10 | Accuracy | 99,46% | 97,01% | 98,87% |
| | Precision | 99,46% | 96,96% | 98,88% |
| | Recall | 99,46% | 97,01% | 98,87% |
| | F1-Score | 99,44% | 96,88% | 98,88% |

4.7 Perbandingan Model

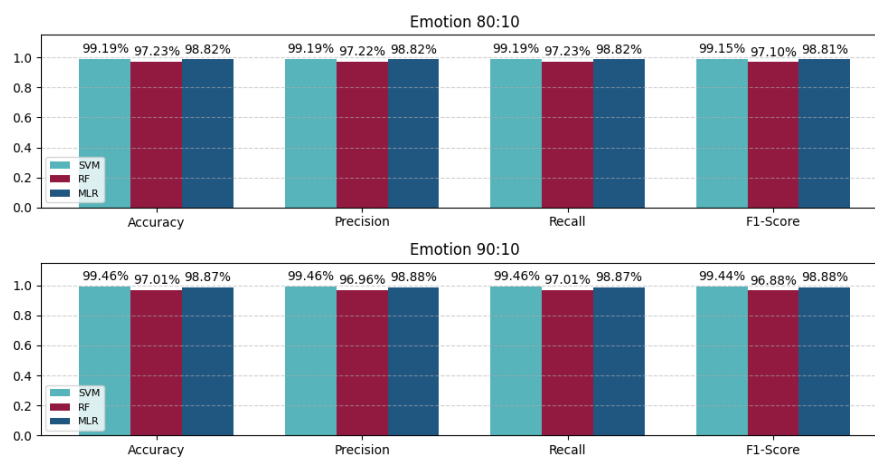
Perbandingan kinerja model dilakukan berdasarkan metrik evaluasi (*accuracy*, *precision*, *recall*, *f1-score*) dan rasio *split* data (80:20 dan 90:10) untuk klasifikasi aspek, sentimen, dan emosi. Hasil divisualisasikan dalam *bar chart* untuk memudahkan identifikasi model terbaik.



Gambar 4. Bar chart perbandingan evaluasi aspek



Gambar 5. Bar chart perbandingan evaluasi sentimen

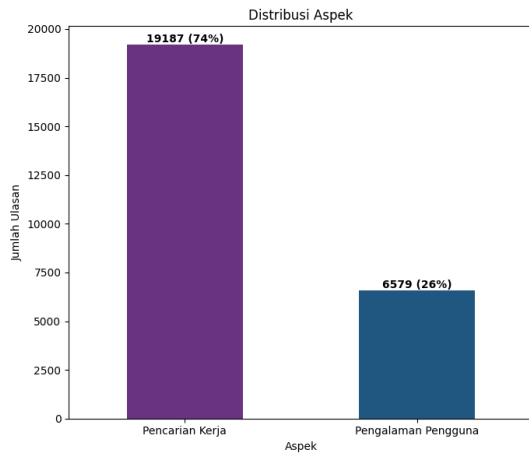


Gambar 6. Bar chart perbandingan evaluasi emosi

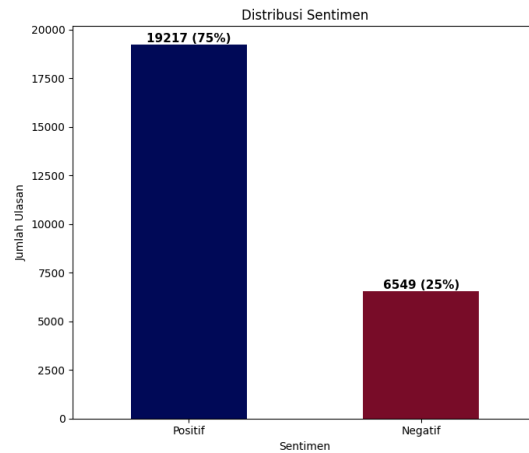
Berdasarkan hasil evaluasi, model terbaik untuk klasifikasi aspek adalah *Support Vector Machine* dengan rasio 90:10, memperoleh akurasi 97,67%, presisi 97,75%, *recall* 97,67%, dan *f1-score* 97,69%. Untuk klasifikasi sentimen, model terbaik adalah *Multinomial Logistic Regression* dengan rasio 90:10, mencatat akurasi 94,49%, presisi 94,98%, *recall* 94,49%, dan *f1-*

score 94,60%. Sementara itu, klasifikasi emosi paling optimal menggunakan *Support Vector Machine* rasio 90:10, dengan akurasi, presisi, dan *recall* sebesar 99,46%, serta *f1-score* 99,44%.

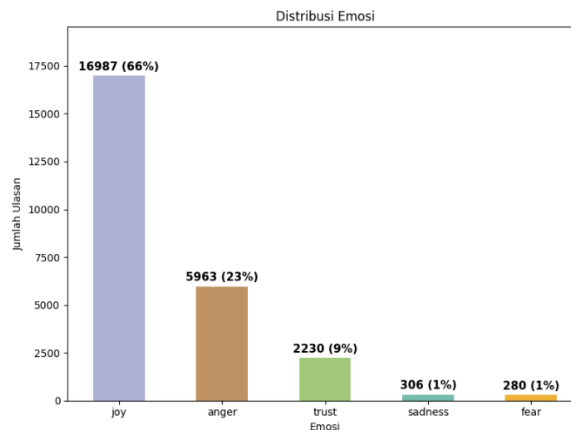
4.8 Visualisasi Data dan Hasil



Gambar 7. Visualisasi distribusi aspek




Gambar 8. Visualisasi distribusi sentimen




Gambar 9. Visualisasi distribusi emosi

Hasil anotasi menunjukkan bahwa sebagian besar ulasan membahas aspek Pencarian Kerja (74%), sementara Pengalaman Pengguna hanya 26%. Dari sisi sentimen, ulasan positif mendominasi dengan 75%, sedangkan negatif 25%. Untuk emosi, *joy* paling banyak muncul (66%), disusul *anger* (23%) dan *trust* (9%), sementara *sadness* dan *fear* hanya masing-masing 1%. Temuan ini menunjukkan bahwa mayoritas ulasan bersifat positif dan berfokus pada aspek pencarian kerja.




Gambar 10. Line chart aspek aplikasi glints per tahun




Gambar 11. Line chart aspek aplikasi jobstreet per tahun

Mayoritas ulasan pengguna Glints dan Jobstreet menyoroti pencarian kerja. Di Glints, fokus ini terus meningkat hingga 2023 dan tetap dominan sampai awal 2025. Sebaliknya, di Jobstreet,

sejak 2024 perhatian bergeser ke pengalaman pengguna yang makin mendominasi hingga awal 2025.




Gambar 10. Line chart sentimen aplikasi glints per tahun




Gambar 11. Line chart sentimen aplikasi jobstreet per tahun

Sentimen aspek pencarian kerja di Glints dan Jobstreet didominasi positif, namun aspek pengalaman pengguna lebih banyak mendapat sentimen negatif. Sentimen terhadap Glints membaik sejak 2021, puncak di 2023 hingga awal 2025. Sebaliknya, Jobstreet mengalami penurunan, dari dominan positif hingga 2023 menjadi dominan negatif dari 2024 hingga awal 2025.



Gambar 10. Line chart emosi aplikasi glints per tahun



Gambar 11. Line chart emosi aplikasi jobstreet per tahun

Emosi dominan dalam ulasan positif pada aplikasi Glints dan Jobstreet adalah *joy*, diikuti oleh *trust*, sedangkan ulasan negatif didominasi oleh *anger*. Pada Glints, proporsi emosi *joy* menunjukkan penurunan dari tahun 2021 hingga awal 2025, sebaliknya *anger* mengalami peningkatan. Tren serupa terlihat pada Jobstreet, dengan penurunan signifikan emosi *joy* dan lonjakan emosi *anger* dalam dua tahun terakhir. Hal ini mengindikasikan adanya penurunan kepuasan dan meningkatnya ketidakpuasan pengguna terhadap aplikasi, khususnya dalam periode waktu tersebut.

5. KESIMPULAN

Penelitian ini menyimpulkan bahwa model dengan performa terbaik untuk klasifikasi aspek dan emosi adalah *Support Vector Machine*, sedangkan untuk klasifikasi sentimen adalah *Multinomial Logistic Regression*, dengan rasio *split* data 90:10 yang konsisten menghasilkan hasil terbaik. Ulasan pengguna didominasi oleh aspek Pencarian Kerja dan sentimen positif, dengan emosi *joy* sebagai emosi paling menonjol, sementara *fear* paling jarang muncul. Pada aplikasi Glints, fokus ulasan tetap pada pencarian kerja, namun kepuasan menurun sejak 2024 seiring meningkatnya emosi *anger* pada aspek pengalaman pengguna. Sementara itu, ulasan Jobstreet menunjukkan pergeseran fokus ke aspek pengalaman pengguna sejak 2024, yang didominasi sentimen negatif dan emosi *anger*. Temuan ini menegaskan perlunya perbaikan pada aspek pengalaman pengguna untuk meningkatkan kepuasan secara keseluruhan.

6. DAFTAR PUSTAKA

- [1] U. Sugiarti, "Tagar 'Desperate' Ramai di LinkedIn, Gen Z Kesulitan Cari Kerja," *GoodStats*, 2024. [Online]. Available: <https://goodstats.id/article/tagar-desperate-ramai-di-linkedin-kesulitan-gen-z-mencari-kerja-bNzcJ>. [Accessed: Jan. 26, 2025].

-
- [2] Y. Taufiqurrahman, “Persentase ‘Sarjana Pengangguran’ di RI Meningkatkan Dua Kali Lipat Selama 1 Dekade Terakhir,” *GoodStats*, 2024. [Online]. Available: <https://data.goodstats.id/statistic/persentase-sarjana-pengangguran-di-ri-meningkat-dua-kali-lipat-selama-1-dekade-terakhir-9ah2d>. [Accessed: Jan. 27, 2025].
 - [3] S. A. Saputra, D. Rosiyadi, W. Gata, and S. M. Husain, “Google Play E-Wallet Sentiment Analysis Using Naïve Bayes Algorithm Based on Particle Swarm Optimization,” *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 3, no. 3, pp. 377–382, 2019.
 - [4] A. R. Satria, S. Adinugroho, and Suprpto, “Analisis Sentimen Ulasan Aplikasi Mobile menggunakan Algoritma Gabungan Naïve Bayes dan C4.5 berbasis Normalisasi Kata Levenshtein Distance,” *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 4, no. 11, pp. 4154–4163, 2020.
 - [5] S. Fransiska, Rianto, and A. I. Gufroni, “Sentiment Analysis Provider by.U on Google Play Store Reviews with TF-IDF and Support Vector Machine (SVM) Method,” *Scientific Journal of Informatics*, vol. 7, no. 2, 2020.
 - [6] T. Hastie, R. Tibshirani, and J. Friedman, *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, 2nd ed. New York: Springer, 2021.
 - [7] R. Andreswari and M. A. Hasibuan, “Sentiment analysis of social media Twitter with case of Anti-LGBT campaign in Indonesia using Naive Bayes, decision tree, and random forest algorithm,” *Procedia Computer Science*, vol. 161, pp. 765–772, 2019.
 - [8] S. R. Darawsheh, A. S. Al-Shaar, F. A. Haziemeh, and M. T. Alshurideh, “Classification Thyroid Disease Using Multinomial Logistic Regressions (LR),” *Studies in Computational Intelligence*, vol. 1056, pp. 645–659, 2023.
 - [9] B. T. Hung, “Joining Aspect Detection and Opinion Target Expression Based on Multi-Deep Learning Models,” *Springer Series in Reliability Engineering*, pp. 85–96, 2023.
 - [10] M. N. Alrasheedy, R. C. Muniyandi, and F. Fauzi, “Text-Based Emotion Detection and Applications: A Literature Review,” in *Proc. Int. Conf. on Cyber Resilience (ICCR)*, 2022.
 - [11] D. Sathya, V. Sudha, and D. Jagadeesan, “Application of machine learning techniques in healthcare,” in *Research Anthology on Machine Learning Techniques, Methods, and Applications*, pp. 1294–1310, 2022.
 - [12] R. Sharma, J. Sandhu, and V. Bharti, “Experimental Analysis of a Multimodal Biometric System using Preprocessing and Feature Extraction Techniques and Their Impact on Analytical Results,” in *Proc. 6th Int. Conf. on Computational Intelligence and Communication Technologies (CCICT)*, 2024, pp. 212–219.
-