

DASHBOARD BERBASIS *CONVOLUTIONAL NEURAL NETWORK* UNTUK KELOMPOK SENTIMEN DI PENDIDIKAN TINGGI INDONESIA

CONVOLUTIONAL NEURAL NETWORK-BASED DASHBOARD FOR
SENTIMENT CLIQUES IN INDONESIAN HIGHER EDUCATION

**Made Rahayu Putri Saron¹, Rokhmatul Insani², Mochamad Nizar Palefi Ma'ady³, Alqis
Rausanfita^{4*}**

*E-mail: alqisfita@telkomuniversity.ac.id

^{1,2,3}Program Studi Sistem Informasi, Universitas Telkom, Kampus Surabaya

⁴Program Studi Informatika, Universitas Telkom, Kampus Surabaya

Abstrak

Dashboard Evaluasi Dosen oleh Mahasiswa (EDOM) merupakan aspek penting dalam peningkatan pengembangan pendidikan tinggi. EDOM berperan penting dalam mengukur kualitas kinerja dan memberikan umpan balik yang berdampak pada dosen. Meskipun EDOM dilakukan secara rutin, pemanfaatan data EDOM masih belum optimal dalam menghasilkan informasi yang signifikan bagi dosen dan institusi pendidikan, khususnya di Institut Teknologi Telkom Surabaya (ITTelkom Surabaya). Penelitian ini menggunakan pendekatan eksperimental dengan menerapkan analisis sentimen umpan balik terhadap kinerja dosen EDOM di ITTelkom Surabaya menggunakan *Convolutional Neural Network (CNN)* dan *Word2Vec*. Penelitian ini melibatkan tahapan pengumpulan data EDOM, pra-pemrosesan data yang mencakup pelabelan sentimen seperti negatif, netral, atau positif dengan *SentiStrength* dan *Word embedding* menggunakan *Word2Vec*, pelatihan dan evaluasi model *CNN* untuk analisis sentimen data teks, serta pengembangan dashboard yang dapat menampilkan hasil analisis secara visual. Penelitian ini menggunakan dua arsitektur *CNN*, yaitu *Simple CNN* dan *Double Max CNN*. Berdasarkan hasil pengujian, *Double Max CNN* dapat mengklasifikasikan sentimen pada saran mahasiswa dengan sangat baik, mencapai akurasi tertinggi 86%, *recall* 69%, *precision* 74% dan *f1-score* 70%. Sementara *Simple CNN* dapat mengklasifikasikan sentimen pada saran mahasiswa dengan sangat baik, mencapai akurasi tertinggi 82%, *recall* 69%, *precision* 74%, dan *f1-score* 67% serta dashboard interaktif yang menampilkan data EDOM.

Kata kunci: Convolutional Neural Network, Word2Vec, EDOM, Analisis Sentimen, ITTelkom Surabaya.

Abstract [Times New Roman 11 Normal Justify]

Evaluation Dashboard of Lecturers by Students (EDOM) is an important aspect in the increasing development of higher education. EDOM plays an important role in measuring the quality of performance and providing feedback that has an impact on lecturers. Although EDOM is routinely conducted, the utilization of EDOM data is still not optimal in producing significant information for lecturers and educational institutions, especially at Telkom Institute of Technology Surabaya (ITTelkom Surabaya). This research uses an experimental approach by applying sentiment feedback analysis to EDOM lecturer performance at ITTelkom Surabaya using Convolutional Neural Network (CNN) and Word2Vec. This research involves the stages of EDOM data collection, data preprocessing which includes sentiment labeling such as negative, neutral, or positive with SentiStrength and word embedding using Word2Vec, training and evaluation of CNN models for sentiment analysis of text data, as well as the development of a

dashboard that can display analysis results visually. This research uses two CNN architectures, namely Simple CNN and Double Max CNN. Based on the test results, Double Max CNN can classify sentiment on student suggestions very well, achieving the highest accuracy of 86%, recall 69%, precision 74% and f1-score 70%. While Simple CNN can classify sentiment on student suggestions very well, achieving the highest accuracy of 82%, recall 69%, precision 74%, and f1-score 67% as well as an interactive dashboard that displays EDOM data.

Keywords: Convolutional Neural Network, Word2Vec, EDOM, Sentiment Analysis, ITTelkom Surabaya

1. PENDAHULUAN

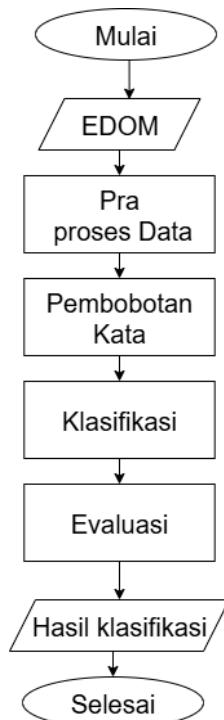
Pendidikan tinggi merupakan fondasi penting dalam pembentukan individu yang kompeten, berkualitas, dan siap bersaing di dunia kerja. Kinerja dosen merupakan salah satu aspek terpenting dalam proses pendidikan tinggi. Dosen berperan dalam meningkatkan akreditasi dan kualitas penyelenggara pendidikan, tetapi tanggung jawab utama mereka adalah mengajar, menginformasikan, membimbing, melatih, dan memaksimalkan potensi siswa. Melalui evaluasi, dosen dapat memperoleh informasi mengenai tingkat keberhasilan dalam proses belajar-mengajar, tanggapan siswa terhadap dosen, dan sebagai *Key Performance Indicator (KPI)* yang digunakan untuk memantau pencapaian kinerja. Evaluasi berperan dalam mengukur kemampuan individu dan memastikan keunggulan dan kualitas pendidikan di institusi. Namun, dalam beberapa kasus, hasil evaluasi dosen belum sepenuhnya dimanfaatkan secara efektif untuk meningkatkan kualitas pengajaran dan kinerja dosen.

Di Institut Teknologi Telkom Surabaya (IT-Telkom Surabaya) yang kini telah berubah menjadi Universitas Telkom Surabaya, Evaluasi Dosen oleh Mahasiswa (EDOM) selalu dilakukan setiap semester untuk mendapatkan umpan balik mengenai kinerja dosen. Meskipun survei evaluasi dosen dilakukan secara rutin, hingga saat ini IT-Telkom Surabaya belum memiliki platform yang dapat memudahkan dosen dan institusi untuk menampilkan visualisasi analisis data EDOM. Oleh karena itu, diperlukan pendekatan baru yang lebih efektif dalam menganalisis dan menginterpretasikan hasil evaluasi dosen agar dapat memberikan manfaat yang lebih berdampak dalam meningkatkan kualitas pengajaran.

Knowledge Discovery in Databases (KDD) merupakan pendekatan metodologis yang dirancang untuk mengidentifikasi, mengekstrak, dan menginterpretasikan wawasan signifikan dari basis data besar [1]. Dalam penelitian ini, teknik *KDD* diterapkan untuk menganalisis umpan balik siswa terhadap kinerja dosen menggunakan data Evaluasi Penyampaian dan Operasi Modul (EDOM), yang terdiri dari tanggapan tekstual siswa. Penelitian ini mengintegrasikan algoritma *Word2Vec* untuk menyematkan kata-kata dari saran siswa dan menggunakan *Convolutional Neural Network (CNN)* untuk analisis sentimen. *CNN* digunakan karena kemampuannya yang baik dalam mengenali pola yang kompleks [2]. Analisis komparatif dengan dataset film untuk klasifikasi sentimen ulasan film menggaris bawahi keefektifan model *CNN*, yang mencapai akurasi 79%, secara signifikan mengungguli model *Recurrent Neural Network (RNN)*, yang mencatat akurasi 70% [3]. Penelitian lainnya juga membandingkan metode *CNN* dan Naïve bayes untuk mengetahui sentimen Masyarakat terhadap vaksin Covid-19, *CNN* mendapatkan hasil akurasi lebih besar dengan nilai 98,66%, sedangkan naïve bayes hanya 94,66% [4]. Penelitian lainnya menggunakan metode *CNN* untuk menganalisis sentimen pada data tweets yang diambil dari media social twitter dengan kata kunci kuliah daring dan mendapatkan nilai akurasi sebesar 82,86% [5]. Selanjutnya, penelitian ini meningkatkan penerapan praktis temuan-temuannya dengan memvisualisasikan hasil analisis sentimen dari data EDOM pada dashboard interaktif.

Dashboard ini dirancang untuk menampilkan grafik intuitif yang menggambarkan tren sentimen selama tiga semester dan distribusi sentimen di antara tanggapan. Selain itu, fitur word cloud kalimat akan memberikan ringkasan visual dari tema-tema berulang dalam umpan balik siswa mengenai kinerja dosen, memfasilitasi interpretasi data yang lebih langsung dan mudah dipahami bagi administrator.

2. METODOLOGI



Gambar 1. Diagram Alir system

Data yang digunakan dalam penelitian ini adalah data EDOM dari ITTelkom Surabaya, dengan periode semester genap 2021/2022, ganjil 2022/2023 dan genap 2022/2023. Peneliti mengumpulkan data EDOM berupa saran dan pertanyaan berdasarkan fakultas, program studi dan nama mata kuliah dari universitas. Sentimen dari data EDOM yang berupa teks bisa diketahui dengan beberapa tahapan, yaitu pra proses data, pembobotan kata, klasifikasi, dan terakhir evaluasi.

2.1 Pra proses Data

Pra-pemrosesan adalah tahapan untuk membersihkan, mengintegrasikan, memformat ulang, dan menyesuaikan data agar sesuai dengan kebutuhan analisis atau pemodelan yang akan dilakukan. Pada tahap ini, beberapa tahapan dilakukan untuk mempersiapkan data, yaitu case folding, tokenisasi, penghapusan stop word, penghapusan tanda baca, dan *Stemming* menggunakan pustaka *Natural Language Toolkit (NLTK)*, *Re*, *String* dan *Sastrawi*. Proses tokenisasi bertujuan untuk memecah sebuah string teks menjadi potongan-potongan yang bermakna [6]. *CASEFOLDING* adalah proses pengubahan huruf kapital menjadi huruf kecil [7][8]. *Stopwords* adalah daftar kata yang sering muncul sehingga jika tetap ada bisa menjadi *noise* [9]. *Stemming* merupakan suatu teknik normalisasi teks yang bertujuan untuk mereduksi suatu kata bentukan menjadi bentuk

dasarnya yang disebut kata dasar (*stem*) dengan menghilangkan afiks (prefiks, sufiks, infiks, dan konfiks) [10].

Pada tahap ini juga dilakukan anotasi data. Anotasi data adalah memberikan label atau skor sentimen pada data teks untuk mengidentifikasi dan memetakan polaritas emosi yang terkandung dalam teks. Proses anotasi data dalam analisis sentimen melibatkan penilaian subjektif dengan memberikan label sentimen positif, negatif, atau netral berdasarkan interpretasi ekspresi emosional. Dalam penelitian ini, anotasi data dilakukan menggunakan SentiStrength dalam bahasa Indonesia untuk mendapatkan label negatif, netral dan positif.

SentiStrength adalah kerangka kerja algoritmik yang dirancang untuk menilai dan memberikan bobot numerik pada kata atau frasa berdasarkan polaritas sentimennya [11]. Alat ini mengkuantifikasi sentimen positif dan negatif, memberikan nilai pada skala dari 1 hingga 5. Peringkat 1 menandakan sentimen netral, sedangkan peringkat 5 menunjukkan kalimat sangat positif atau sangat negatif, tergantung pada konteksnya. Penerapan algoritma *SentiStrength* mengikuti pedoman khusus: sebuah sentimen diklasifikasikan sebagai positif jika skor positif melebihi skor negatif, sebagai negatif jika skor positif kurang dari skor negatif, dan sebagai netral jika skornya setara. Pendekatan sistematis ini memfasilitasi analisis sentimen yang bermuansa dengan membedakan berbagai tingkat intensitas sentimen.

2.2 Pembobotan Kata

Data berupa teks harus dilakukan transformasi terlebih dahulu dengan menghitung bobot kata, namun untuk melakukan penghitungan bobot harus dilakukan ekstraksi fitur terlebih dahulu. Ekstraksi fitur dilakukan dengan menerapkan model *Word2Vec* untuk meningkatkan representasi kata. *Word2Vec* merupakan metode terobosan dalam bidang representasi vektor kata semantik. Teknik ini dirancang untuk mengekstrak vektor kata berkualitas tinggi dari kumpulan data yang luas, secara signifikan meningkatkan deteksi kesamaan kata dan memfasilitasi operasi aritmatika vektor yang presisi [12]. *Word2Vec* menghasilkan dense vector yang mampu merepresentasikan relasi semantik dan sintaksis antar kata dalam kumpulan data saran dengan efektif [13].

Word2Vec menggunakan arsitektur jaringan saraf tiruan untuk menghasilkan vektor-vektor ini, mencakup dua model berbeda: *Continuous Bag of Words (CBOW)* dan *Skip-gram*. Model *CBOW* memprediksi kata target berdasarkan konteks di sekitarnya, sehingga meningkatkan kapasitas algoritma untuk menyimpulkan makna dari kata-kata yang berdekatan. Sebaliknya, model *Skip-gram* berfungsi dengan cara yang berlawanan dengan memprediksi lingkungan kontekstual dari sebuah kata target, sehingga memperkaya kemampuannya untuk memahami asosiasi kata dan nuansa kontekstual. Pendekatan arsitektur ganda ini memungkinkan pemrosesan semantik yang kuat di berbagai kumpulan data linguistik.

Model *Word2Vec*, yang dilatih pada korpus Wikipedia bahasa Indonesia yang substansial yang mencakup 507.912 artikel dan 153.994.482 kalimat, diimplementasikan menggunakan pustaka Gensim. Pelatihan ini tidak hanya meningkatkan pemahaman semantik kata-kata tetapi juga menyempurnakan word embedding melalui fine-tuning dengan bantuan data saran. Ini bertujuan untuk mempersiapkan data untuk klasifikasi sentimen yang efisien menggunakan *CNN*.

2.3 Klasifikasi

Pada tahap ini akan dilakukan klasifikasi menggunakan metode *CNN*. *Convolutional Neural Network (CNN)* adalah salah satu arsitektur jaringan saraf tiruan yang dapat mengidentifikasi informasi dengan berbagai peristiwa secara akurat, sering digunakan untuk pengolahan citra, pengenalan pola, dan struktur komponen yang terdiri dari lapisan konvolusi, lapisan pooling, dan lapisan terhubung penuh [14]. Arsitektur *CNN* dikategorikan menjadi *Simple CNN* dan *Double*

Max CNN. Konfigurasi Simple *CNN* menggunakan dua lapisan konvolusi, memuncak pada operasi *max pooling* pada tahap terminal untuk mengurangi dimensi spasial dan jumlah parameter. Sebaliknya, model Double *Max CNN* menggabungkan dua lapisan *max pooling* setelah setiap lapisan konvolusi, sehingga meningkatkan ekstraksi fitur dan mengurangi *overfitting* dengan secara sistematis mengurangi volume spasial dari representasi input melalui setiap lapisan berturut-turut.

Sebelum dilakukan klasifikasi, data dibagi dengan persentase 80% data pelatihan, 10% data validasi dan 10% data uji. Untuk pengenalan pola dan fitur dalam teks terkait sentimen, dua arsitektur *Convolutional Neural Network (CNN)* digunakan yaitu Simple *CNN* dan Double *Max CNN*. Simple *CNN* digunakan terutama untuk mempelajari pola dan fitur yang ada dalam data. Sementara itu, arsitektur Double *Max CNN*, yang mengintegrasikan lapisan konvolusi dengan lapisan max pooling, secara khusus dirancang untuk meningkatkan ekstraksi pola yang relevan, sehingga memfasilitasi hasil pembelajaran dan prediksi yang lebih efektif [13].

Model Double *Max CNN* menggunakan dua set lapisan *Conv1D* dengan 32, 64, dan 128 filter, dan ukuran kernel 5, serta aktivasi ReLU, diikuti oleh *MaxPooling1D* dengan ukuran pool 2 untuk mengurangi dimensionalitas fitur. Kemudian, output diratakan dan dilewatkan melalui dua lapisan *Dense*, dengan hasil akhir 3 unit softmax untuk klasifikasi tiga kelas sentimen. Model dikompilasi dengan pengoptimal Adam dan metrik akurasi dan dievaluasi selama 5 epoch dengan ukuran *batch* 15. Model Simple *CNN* menggunakan dua lapisan *Conv1D* dengan *filter* serupa, diikuti oleh *MaxPooling1D* untuk reduksi dimensionalitas fitur, dan penggunaan *Dense* untuk klasifikasi sentimen. Setelah proses pelatihan selesai dan model telah diuji dengan data validasi, langkah selanjutnya adalah menguji model pada data uji yang benar-benar baru yang sebelumnya belum digunakan selama pelatihan dan validasi.

2.4 Evaluasi

Evaluasi model dilakukan menggunakan metode *confusion matrix* dengan membandingkan hasil prediksi model dengan label aktual dari data uji berdasarkan metrik akurasi, presisi, *recall*, dan *F1-score*, untuk mengukur kinerja dan akurasi model dalam mengklasifikasikan sentimen. Dalam evaluasi kinerja algoritma, *confusion matrix* memegang peran yang sangat penting. Matriks ini secara sistematis menyajikan distribusi hasil prediksi suatu model dibandingkan dengan nilai sebenarnya [15]. *Confusion matrix* merupakan metrik kritis untuk mengevaluasi keefektifan model prediktif dengan memberikan wawasan terperinci melalui berbagai indeks kinerja. Matriks ini terdiri dari serangkaian nilai yang mengkategorikan prediksi menjadi empat jenis berbeda: *True Positives*, di mana instance positif diidentifikasi secara akurat sebagai positif; *True Negatives*, di mana instance negatif diklasifikasikan dengan benar; *False Positives*, yang secara tidak benar memberi label instance negatif sebagai positif; dan *False Negatives*, di mana instance positif secara salah diklasifikasikan sebagai negatif [16].

Setelah didapatkan hasil sentimen tiap data, maka akan dilakukan proses integrasi data dan pengembangan dashboard dengan menentukan tata letak, grafik, dan visualisasi yang diperlukan. Dashboard dirancang menggunakan Looker Studio. Looker studio merupakan platform visualisasi data untuk merepresentasikan Kumpulan data yang rumit [17]. Hal ini menjadi dasar dalam penggunaan Looker Studio untuk menampilkan visualisasi data EDOM berdasarkan fakultas, program studi, dan mata kuliah serta pertanyaan.

3. HASIL DAN PEMBAHASAN

3.1 Anotasi Data

Anotasi data dilakukan menggunakan *SentiStrength* Bahasa Indonesia. Data diklasifikasikan berdasarkan skor sentimen. Label positif (1) diberikan ketika skor kata positif melebihi negatif dan netral. Sebaliknya, label negatif (0) diberikan jika kata negatif atau netral mendominasi skor, dan label netral (2) digunakan ketika sentimen netral adalah yang tertinggi dibandingkan dengan sentimen negatif dan positif. Hasil penerapan *SentiStrength* untuk menganotasi data menghasilkan data dengan 8.357 sentimen positif, 4.749 netral dan 725 data negatif.

3.2 Hasil Klasifikasi

Dalam evaluasi kinerja yang dirinci pada Tabel 1, dua arsitektur CNN dianalisis yaitu *Simple CNN* dan *Double Max CNN*, menggunakan ukuran filter 32, 64, dan 128. Evaluasi menunjukkan bahwa dalam konfigurasi *Simple CNN*, penggunaan ukuran filter 128 meningkatkan kinerja jaringan, mencapai tingkat *recall* 69%, *precision* 66%, akurasi 82%, dan *F1-Score* 67%. Sebaliknya, arsitektur *Double Max CNN* menunjukkan kinerja optimal dengan ukuran filter terkecil 32, mencapai tingkat *recall* 69%, *precision* 74%, akurasi 86%, dan *F1-Score* 70%. Metrik ini menyoroti keefektifan superior *Double Max CNN* dalam pengenalan pola dan data.

Tabel 1. Hasil Klasifikasi

Arsitektur	Filter	Recall (%)	Precision (%)	Akurasi (%)	F1-Score (%)
Simple CNN	32	67	70	84	68
	64	65	70	84	67
	128	69	66	82	67
Double CNN	32	69	74	86	70
	64	65	73	83	68
	128	70	73	86	71

Hasil klasifikasi menunjukkan bahwa ia dapat menawarkan kemampuan prediktif yang lebih kuat dibandingkan dengan model Simple CNN. Perbandingan ini menunjukkan dampak signifikan dari pilihan arsitektur dan penyesuaian parameter pada keefektifan jaringan saraf dalam analisis sentimen.

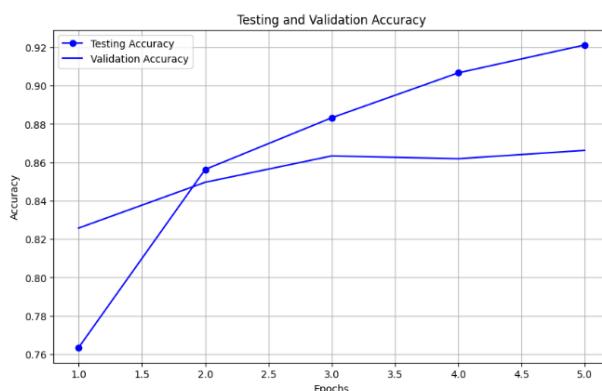
3.3 Evaluasi Model

Evaluasi dilakukan dengan menerapkan *confusion matrix*. *Confusion matrix* pada Gambar 2 menunjukkan kinerja model CNN dengan arsitektur Simple CNN dalam tugas klasifikasi sentimen dengan mengklasifikasikan label positif dan netral dengan 701 dan 407 prediksi akurat, namun, model kurang efektif dalam mengenali label negatif dengan hanya 27 prediksi benar. Ada juga kesalahan klasifikasi yang signifikan dari label negatif ke label lain, menunjukkan potensi bias model terhadap kelas positif dan netral.



Gambar 2. Confusion matrix simple CNN

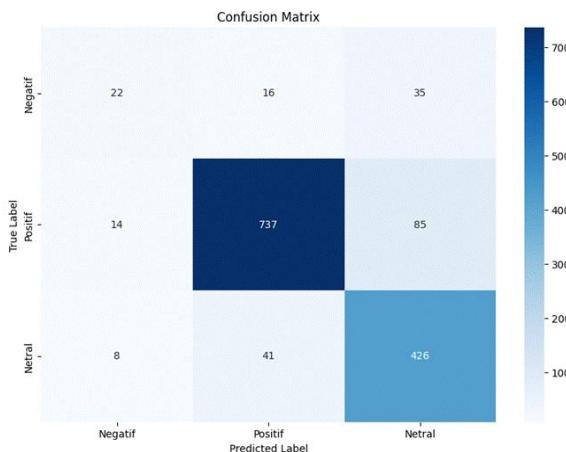
Model Simple CNN memiliki presisi tinggi untuk sentimen positif 93% dan netral 76%, tetapi lebih rendah untuk negatif 31%. Sementara itu memiliki recall yang baik untuk netral 86% dan positif 84%, model masing-masing kurang efektif dalam mengenali negatif 37%. Score-F1 menunjukkan keseimbangan, dengan kinerja terbaik untuk positif 88% dan netral 80%, tetapi lebih rendah untuk negatif 34%. Akurasi pada data pelatihan adalah 82% dan pengujian 96%, dengan model terbaik dalam mengklasifikasikan positif dan netral sementara negatif perlu peningkatan.



Gambar 3. Akurasi selama pelatihan dan evaluasi pada setiap epoch menggunakan Simple CNN

Model Double Max CNN berhasil mengklasifikasikan 737 sentimen positif dan 426 sentimen netral dengan benar, menunjukkan kinerja yang solid dalam kedua kategori. Namun, ada kesalahan signifikan dalam mengenali sentimen negatif, kesalahan ini menunjukkan bahwa meskipun model cukup kompeten dalam mengidentifikasi sentimen positif dan netral, model

mengalami kesulitan dengan sentimen negatif, yang memerlukan tinjauan lebih lanjut dan penyesuaian model untuk meningkatkan akurasi.



Gambar 4. Confusion matrix double max CNN



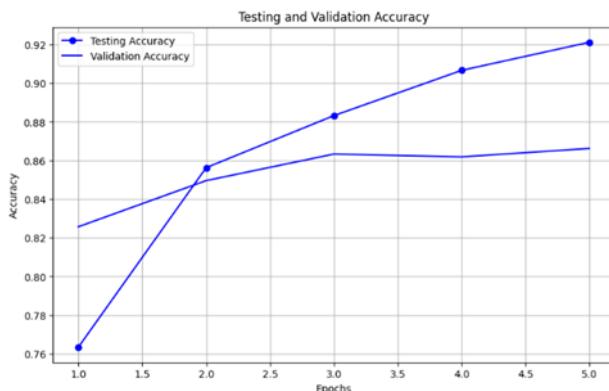
Gambar 5. Dashboard evaluasi sentimen terhadap kinerja dosen



Gambar 6. Dashboard evaluasi penilaian mahasiswa terhadap kinerja dosen

Model *Double Max CNN* memiliki presisi tinggi untuk positif 90% dan netral 84%, tetapi lebih rendah untuk negatif 52%. Berdasarkan hasil *recall*, model ini baik dalam mengenali netral 90% dan positif 86%, tetapi kurang efisien dalam mengenali negatif 45%. *F1-score*, yang menggabungkan presisi dan *recall*, menunjukkan kinerja terbaik untuk positif 88% dan netral 87%, dengan skor lebih rendah untuk negatif 48%. Dengan akurasi data pelatihan 86% dan data

pengujian 94%, model efektif dalam mengklasifikasikan sentimen, terutama positif dan netral, tetapi memerlukan peningkatan dalam mengenali negatif. Analisis lebih lanjut, seperti digambarkan pada Gambar 4 dan Gambar 7, menunjukkan bahwa model mempertahankan potensi untuk kemajuan pembelajaran tanpa risiko overfitting yang substansial. Ini disimpulkan dari kesenjangan modest antara kurva akurasi pelatihan dan validasi, menunjukkan model yang seimbang yang disetel dengan baik untuk menggeneralisasi data baru yang belum pernah dilihat sambil mempertahankan tingkat akurasi tinggi dalam klasifikasi sentimen.



Gambar 7. Akurasi selama pelatihan dan evaluasi pada setiap epoch menggunakan double max CNN

3.4 Dashboard

Pengembangan dashboard menggunakan LookerStudio dilakukan dengan menggabungkan sumber data seperti data saran dengan label yang telah ditetapkan sebelumnya dan data pertanyaan. Dataset ini dikelola dan diintegrasikan melalui Google Sheets. Dashboard dibagi menjadi dua bagian berbeda: dashboard pertama dikhususkan untuk memvisualisasikan data saran seperti Gambar 5, sementara yang kedua berfokus pada menampilkan data pertanyaan seperti Gambar 6. Setiap dashboard dirancang untuk berfungsi secara interaktif, meningkatkan keterlibatan pengguna melalui integrasi daftar dropdown. Daftar ini memungkinkan pengguna untuk memfilter dan menampilkan data sesuai dengan berbagai kriteria termasuk fakultas, program studi, dosen, mata kuliah, dan semester untuk dashboard pertama. Dashboard kedua menawarkan kemampuan pemfilteran tambahan, termasuk jenis pertanyaan. Fungsi interaktif ini memfasilitasi eksplorasi data yang dinamis, memungkinkan pengguna menyesuaikan tampilan informasi dengan kebutuhan analitis spesifik mereka.

4. KESIMPULAN

Berdasarkan hasil pengujian dalam penelitian ini, dapat disimpulkan bahwa penerapan SentiStrength untuk anotasi dan penggunaan model Word2Vec yang dilatih dengan korpus Wikipedia bahasa Indonesia berhasil menghasilkan word embedding yang efektif, yang kemudian digunakan dalam model CNN. Model Double Max CNN dengan 32 filter menunjukkan kinerja yang baik dalam klasifikasi sentimen dengan mencapai akurasi keseluruhan 86%, recall 69%, presisi 74% dan F1-Score 70% dibandingkan dengan model Simple CNN filter 128 yang mendapatkan recall 69%, presisi 66%, akurasi 82% dan F1-Score 67%. Pengembangan dashboard menggunakan Looker Studio memungkinkan visualisasi data yang interaktif dan informatif, dengan kemampuan untuk memfilter data berdasarkan fakultas, program studi, mata kuliah, periode semester serta nama dosen. Secara keseluruhan, model menunjukkan keefektifan dalam

analisis sentimen dan dashboard yang dikembangkan memungkinkan visualisasi data yang intuitif yang berguna untuk interpretasi data lebih lanjut.

5. DAFTAR RUJUKAN

- [1] P. Bethaz and T. Cerquitelli, “Enhancing the friendliness of data analytics tasks: An automated methodology,” *CEUR Workshop Proc.*, vol. 2841, 2021.
- [2] Muhammad Zuama Al Amin, Muhammad Ariful Furqon, and Dwi Wijonarko, “Deteksi Berita Hoaks Berbahasa Indonesia Menggunakan One-Dimensional Convolutional Neural Network,” *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 14, no. 2, pp. 161–169, May 2025, doi: 10.22146/jnteti.v14i2.19050.
- [3] W. Furqoni, I. P. Sindura, I. P. Rahayuningtyas, A. Paunturi, and K. R. Setiani, “Analisis Sentimen Ulasan Film Moana 2 di Website Letterboxd Menggunakan Algoritma CNN dan RNN,” *J. Informatics Interact. Technol.*, vol. 2, no. 1, pp. 284–290, 2025, doi: 10.63547/jiite.v2i1.56.
- [4] F. A. Irawan and D. A. Rochmah, “Penerapan Algoritma CNN Untuk Mengetahui Sentimen Masyarakat Terhadap Kebijakan Vaksin Covid-19,” *J. Inform.*, vol. 9, no. 2, pp. 148–158, 2022, doi: 10.31294/inf.v9i2.13257.
- [5] I. Wulansari and R. Arief, “ANALISIS PERFORMA METODE CONVOLUTIONAL NEURAL NETWORK (CNN) DENGAN WORD EMBEDDING GLOVE PADA KLASIFIKASI SENTIMEN DARI TWITTER,” *J. Ilm. Teknol. dan Rekayasa*, vol. 28, no. 3, pp. 252–264, Dec. 2023, doi: 10.35760/tr.2023.v28i3.6090.
- [6] M. A. Rofiqi, A. C. Fauzan, A. P. Agustin, and A. A. Saputra, “Implementasi Term-Frequency Inverse Document Frequency (TF-IDF) Untuk Mencari Relevansi Dokumen Berdasarkan Query,” *Ilk. J. Comput. Sci. Appl. Informatics*, vol. 1, no. 2, pp. 58–64, Dec. 2019, doi: 10.28926/ilkomnika.v1i2.18.
- [7] A. Dwi Sugiarto and M. Siswo Utomo, “Analisis Sentimen Ulasan Pengguna Bca Mobile Di Google Play Store Menggunakan Metode Decision Tree,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 5, pp. 8004–8009, 2025, doi: 10.36040/jati.v9i5.14969.
- [8] F. Maodah, E. Utami, and S. Sudarmawan, “OPTIMIZING SENTIMENT ANALYSIS OF PRODUCT REVIEWS ON MARKETPLACE USING A COMBINATION OF PREPROCESSING TECHNIQUES, WORD2VEC, AND CONVOLUTIONAL NEURAL NETWORK,” *J. Tek. Inform.*, vol. 4, no. 1, pp. 101–107, Feb. 2023, doi: 10.52436/1.jutif.2023.4.1.815.
- [9] W. Y. Y. Mramra and Y. Nataliani, “Penentuan bidang unggulan akademik universitas melalui metode topik Linear Discriminant Analysis (LDA),” *IT-Explore J. Penerapan Teknol. Inf. dan Komun.*, vol. 4, no. 1, pp. 93–105, 2025, doi: 10.24246/itexplore.v4i1.2025.pp93-105.
- [10] A. A. Magriyanti, “Analisis Pengembangan Algoritma Porter Stemming Dalam Bahasa Indonesia,” *Sekol. Tinggi Elektron. dan Komput. PAT*, vol. 1, no. 1, pp. 1–5, 2018, [Online]. Available: <http://kompas.com>.
- [11] R. W. Hardian, P. E. Prasetyo, U. Khaira, and T. Suratno, “Analisis Sentiment Kuliah Daring Di Media Sosial Twitter Selama Pandemi Covid-19 Menggunakan Algoritma Sentistrength,” *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 1, no. 2, pp. 138–143, Nov. 2021, doi: 10.57152/malcom.v1i2.15.
- [12] K. F. Dewanda, W. M. Rahmawati, S. R. Wardhana, and G. E. Yuliastuti, “Penentuan Relevansi Artikel Ilmiah dengan Metode Word2Vec,” *KERNEL J. Ris. Inov. Bid. Inform. dan Pendidik. Inform.*, vol. 3, no. 2, pp. 9–16, Mar. 2023, doi: 10.31284/j.kernel.2022.v3i2.4038.
- [13] Y. Yuliska, D. H. Qudsi, J. H. Lubis, K. U. Syaliman, and N. F. Najwa, “Analisis Sentimen pada Data Saran Mahasiswa Terhadap Kinerja Departemen di Perguruan Tinggi Menggunakan Convolutional Neural Network,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 8, no. 5, p.

- 1067, Oct. 2021, doi: 10.25126/jtiik.2021854842.
- [14] M. Rhanoui, M. Mikram, S. Yousfi, and S. Barzali, “A CNN-BiLSTM Model for Document-Level Sentiment Analysis,” *Mach. Learn. Knowl. Extr.*, vol. 1, no. 3, pp. 832–847, Jul. 2019, doi: 10.3390/make1030048.
- [15] I. Markoulidakis, G. Kopsiaftis, I. Rallis, and I. Georgoulas, “Multi-Class Confusion Matrix Reduction method and its application on Net Promoter Score classification problem,” *ACM Int. Conf. Proceeding Ser.*, no. Cx, pp. 412–419, 2021, doi: 10.1145/3453892.3461323.
- [16] dan A. D. P. Kubben, M. Dumontier, *Fundamentals of Clinical Data Science*. Cham: Springer International Publishing, 2019.
- [17] A. N. Sihananto, M. Muhamrom, A. Haromainy, and E. Sugiyanto, “Application of Google Data Studio for Data Visualization at SMK Tunas Bangsa Malang,” vol. 2023, pp. 665–669, 2023, doi: 10.11594/nstp.2023.33107.