



**Aspect-based Sentiment Analysis Pada Aplikasi Pelacakan
Kasus Covid-19 (studi kasus: pedulilindungi.id)**

Suryatin

19917016

Tesis diajukan sebagai syarat untuk meraih gelar Magister Komputer

Konsentrasi Sains Data

Program Studi Informatika Program Magister

Fakultas Teknologi Industri

Universitas Islam Indonesia

2023

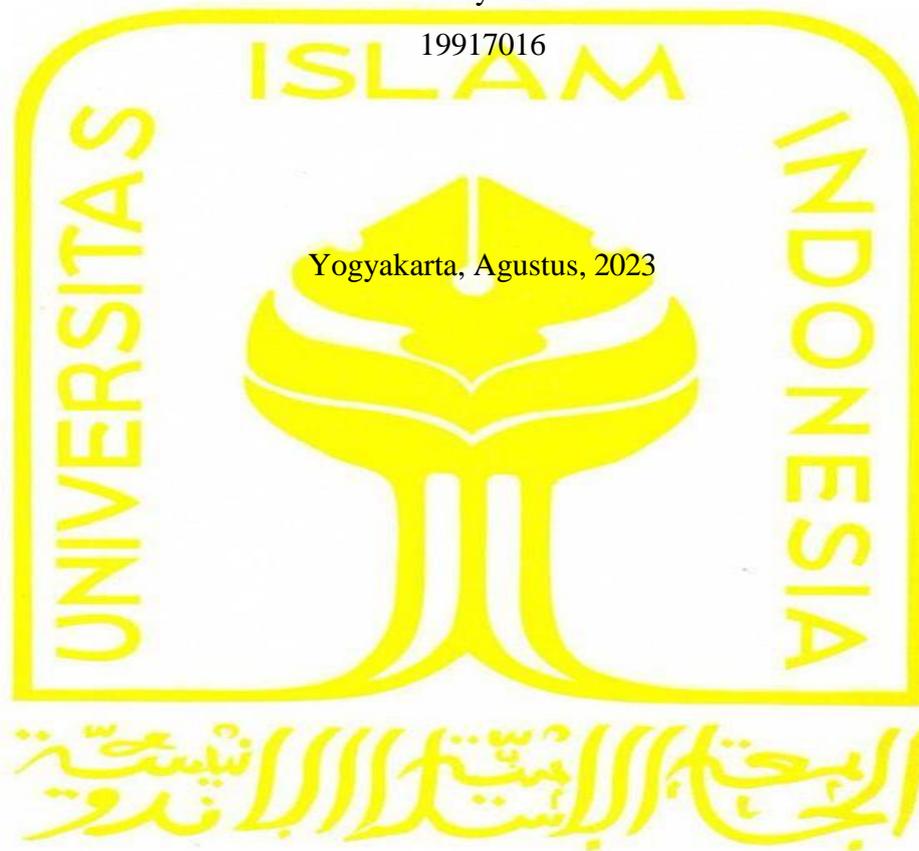
Lembar Pengesahan Pembimbing

Aspect-based Sentiment Analysis Pada Aplikasi Pelacakan Kasus Covid-19

(Studi Kasus: pedulilindungi.id)

Suryatin

19917016



Yogyakarta, Agustus, 2023

Pembimbing I

Dhomas Hatta Fudholi, S.T., M.Eng., Ph.D

Pembimbing II

Chandra Kusuma Dewa., S.Kom., M.Cs., Ph.D

Lembar Pengesahan Penguji

Aspect-based Sentiment Analysis pada Aplikasi Pelacakan Kasus Covid-19 (Syudi Kasus: pedulilindungi.id)

Suryatin
19917016

Yogyakarta, 28 Agustus 2023

Tim Penguji,

Dhomas Hatta Fudholi, S.T., M.Eng., Ph.D.

Ketua

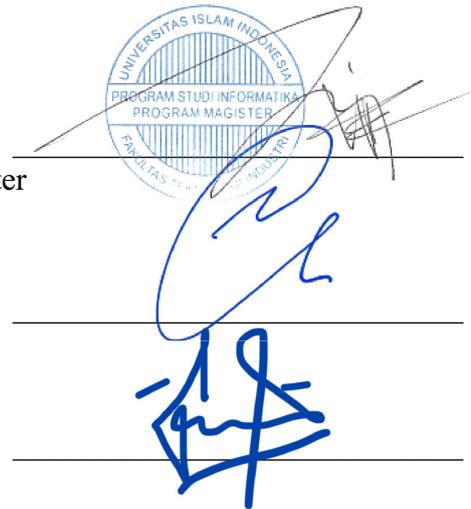
Atas nama Program Studi Informatika Program Magister

Chandra Kusuma Dewa., S.Kom., M.Cs., Ph.D

Anggota I

Mukhammad Andri Setiawan, S.T., M.Sc., Ph.D.

Anggota II



Mengetahui,

Ketua Program Studi Informatika Program Magister

Fakultas Teknologi Industri

Universitas Islam Indonesia



Irving Vitra Paputungan, S.T., M.S

Abstrak

Aspect-based Sentiment Analysis pada Aplikasi Pelacakan Kasus Covid-19

(Studi Kasus: [pedulilindungi.id](https://www.pedulilindungi.id))

Berbagi pengalaman dan pendapat menjadi lebih mudah melalui internet dan media sosial. Pengguna dapat menunjukkan sikap dan perasaan melalui layanan aplikasi yang disediakan. Sikap dan perasaan seseorang dalam menggunakan aplikasi dapat dilihat melalui ulasan aplikasi pintar dalam bentuk informasi umpan balik secara daring. Salah satu aplikasi publik yang banyak disoroti pada masa wabah corona virus adalah aplikasi pedulilindungi. Aplikasi tersebut sebagai salah satu upaya untuk memonitor perkembangan CoronaVirus Disease (Covid-19) di Indonesia dan menjadi salah satu fenomena menarik untuk di kaji dalam memahami perilaku masyarakat Indonesia terhadap aplikasi pedulilindungi yang disebut Aspect-based sentiment. Ulasan yang diberikan oleh setiap pengguna aplikasi dapat digunakan untuk meningkatkan kualitas produk layanan dan memperkenalkan fitur baru. Penelitian bertujuan untuk mengetahui besarnya nilai sentimen pada layanan aplikasi pedulilindungi yang berfokus pada *aspect based sentiment analysis* (ABSA) pada domain ulasan aplikasi pemerintah. *Aspect-based Sentiment Analysis* (ABSA) ulasan aplikasi dengan fokus pada layanan aplikasi pintar yang dapat digunakan dalam analisis sentimen berbasis aspek termasuk antar muka pengguna, pengalaman pengguna, fungsionalitas dan kinerja keamanan. Adanya ulasan dapat membantu dalam memahami nilai baik dan buruk pada sebuah produk atau layanan. Metode yang digunakan meliputi klasifikasi sentimen dan aspek dengan perbandingan tiga metode *deep learning* (CNN, GRU, dan TCN). Data bersumber dari hasil ulasan aplikasi pedulilindungi yang dilakukan dengan cara teknik *scraping* pada situs <https://www.pedulilindungi.id/>. Hasil penelitian menunjukkan bahwa terdapat enam aspek klasifikasi sentimen pada aplikasi pedulilindungi yaitu aplikasi, *user interface*, *user experience*, kode OTP, cek sertifikat vaksin, dan bukti akses layanan. Kemudian hasil penelitian juga menunjukkan dari metode yang digunakan bahwa metode CNN memperoleh nilai skor akurasi terbaik pada klasifikasi sentimen sebesar 0.98 dan klasifikasi aspek sebesar 0.97. Penelitian selanjutnya dapat mengkaji pada aspek yang lebih kompleks pada sebuah aplikasi pelayanan publik atau dengan menggunakan metode yang lebih relevan terhadap objek kajian.

Kata kunci

covid-19, *aspect based sentiment analysis*, aplikasi pedulilindungi, *deep learning*.

Abstract

Aspect-based Sentiment Analysis on Covid-19 Case Tracking Applications (Case Study: [pedulilindungi.id](https://www.pedulilindungi.id/))

Sharing experiences and opinions becomes easier through the internet and social media. Users can show attitudes and feelings through the application services provided. Attitudes and feelings of a person in using the application can be seen through reviews of smart applications in the form of online feedback information. One of the public applications that received much attention during the corona virus outbreak was the care-protect application. This application is one of the efforts to monitor the development of CoronaVirus Disease (Covid-19) in Indonesia and is an interesting phenomenon to study in understanding the behavior of Indonesian people towards the care-protect application called Aspect-based sentiment. Reviews given by each application user can be used to improve the quality of service products and introduce new features. The research aims to determine the magnitude of the sentiment value in the care-protection application service which focuses on aspect-based sentiment analysis (ABSA) in the review domain of government applications. Aspect-based Sentiment Analysis (ABSA) application review with a focus on smart application services that can be used in aspect-based sentiment analysis including user interface, user experience, security functionality and performance. Having reviews can help in understanding the good and bad values of a product or service. The method used includes classification of sentiments and aspects by comparing three deep learning methods (CNN, GRU, and TCN). The data is sourced from the results of a review of the Cares and Protection application which was carried out by means of scraping techniques on the <https://www.pedulilindungi.id/> site. The results of the study show that there are six aspects of sentiment classification in the care-protect application, namely application, user interface, user experience, OTP code, checking vaccine certificates, and proof of service access. Then the results of the study also show that the method used shows that the CNN method obtains the best accuracy score for sentiment classification of 0.98 and aspect classification of 0.97. Subsequent research can examine more complex aspects of a public service application or by using methods that are more relevant to the object of study.

Keywords

covid-19, aspect based sentiment analysis, care-protect application, deep learning

Pernyataan Keaslian Tulisan

Dengan ini saya menyatakan bahwa tesis ini merupakan tulisan asli dari penulis, dan tidak berisi material yang telah diterbitkan sebelumnya atau tulisan dari penulis lain terkecuali referensi atas material tersebut telah disebutkan dalam tesis. Apabila ada kontribusi dari penulis lain dalam tesis ini, maka penulis lain tersebut secara eksplisit telah disebutkan dalam tesis ini.

Dengan ini saya juga menyatakan bahwa segala kontribusi dari pihak lain terhadap tesis ini, termasuk bantuan analisis statistik, desain survei, analisis data, prosedur teknis yang bersifat signifikan, dan segala bentuk aktivitas penelitian yang dipergunakan atau dilaporkan dalam tesis ini telah secara eksplisit disebutkan dalam tesis ini.

Segala bentuk hak cipta yang terdapat dalam material dokumen tesis ini berada dalam kepemilikan pemilik hak cipta masing-masing. Apabila dibutuhkan, penulis juga telah mendapatkan izin dari pemilik hak cipta untuk menggunakan ulang materialnya dalam tesis ini.

Yogyakarta, 31 Agustus 2023



Suryatin., S.Si

Daftar Publikasi

Suryatin, Hatta Fudholi, D., & Kusuma Dewa, C. (2023). Aspect-based Sentiment Analysis on Covid-19 Case Tracking Applications.: Jurnal Sistem Informasi dan Sistem Komputer (SIMKOM) <https://e-jurnal.stmikbinsa.ac.id/index.php/simkom>

Kontributor	Jenis Kontribusi
Suryatin	Memberi ide (65%) Mendesain eksperimen (60%) Menulis dan memperbaiki jurnal (70%)
Dhomas Hatta Fudholi	Memberi ide dan saran (40%) Desain eksperimen (20%) Review jurnal (30%)
Chandra Kusuma Dewa	Memberi ide dan saran (20%) Review jurnal (30%)

Halaman Kontribusi

Penelitian Aspect-based Sentiment Analysis Pada Aplikasi Pelacakan Kasus Covid-19 Studi Kasus Pedulilindungi ini tidak terlepas dari dukungan, saran, serta bimbingan dari Dr. Dhomas Hatta Fudholi dan Chandra Kusuma Dewa., S.Kom., M.Cs., Ph.D. dalam penyelesaian tugas akhir yang berlangsung berbulan-bulan dengan berbagai tantangan yang dihadapi peneliti.

Halaman Persembahan

Bismillahirrahmanirrahim.

Dengan mengucapkan puji syukur kehadirat Allah SWT. Atas segala nikmat dan karunianya yang telah memberikan kemudahan dalam penyelesaian tugas akhir Magister (S2) telah sampai pada tahap ini. Dalam karya penelitian ini saya persembahkan untuk orang-orang yang tulus memberikan dukungan. Terima kasih penulis persembahkan kepada:

1. Kedua orang tua yang senantiasa memberikan doa dan kasih sayang.
2. Kakak yang saya banggakan yang selalu memberikan motivasi serta mensupport penulis untuk terus berkembang.
3. Keponakan yang selalu buat penulis terus bersemangat dalam penyelesaian tugas akhir.
4. Dr. Dhomas Hatta Fudholi dan Candra Kusuma Dewa., S.Kom., M.Cs., Ph.D. yang tanpa henti memberikan saran dan bimbingan dalam penyelesaian studi magister.

Kata Pengantar

Alhamdulillahirabbil'alamin, puji syukur kehadiran Allah SWT yang senantiasa melimpahkan rahmat dan kasih sayang kepada seluruh ciptaan. Tidak lupa pula salawat serta salam kepada junjungan baginda Nabi Muhammad SAW yang telah memperjuangkan umat dari kegelapan menuju cahaya yang terang benderang dengan nafas Islam. Tesis ini disusun sebagai syarat akhir untuk meraih gelar Magister Informatika di Universitas Islam Indonesia (UII) Yogyakarta pada Fakultas Teknologi Industri konsentrasi Sains Data.

Penyelesaian tugas akhir tidak sampai pada tahap ini tanpa pemberian, kesempatan, saran, bimbingan, serta dukungan dari berbagai pihak. Sebagai ucapan rasa terimakasih kepada:

1. Kedua orang tua yang senantiasa memberikan doa dan kasih sayang.
2. Kakak yang saya banggakan yang selalu memberikan motivasi serta mensupport penulis untuk terus berkembang.
3. Bapak Prof. Fathul Wahid, S.T., M.Sc., Ph.D, sebagai rektor Universitas Islam Indonesia (UII).
4. Bapak Irving Vitra Papatungan, S.T., M.Sc. selaku Ketua Program Studi Informatika Program Magister Fakultas Teknologi Industri Universitas Islam Indonesia (UII).
5. Bapak Dr. Dhomas Hatta Fudholi dan Bapak Chandra Kusuma Dewa., S.Kom., M.Cs., Ph.D, selaku dosen pembimbing yang berkontribusi dan berkolaborasi dalam bentuk pemikiran, saran, serta semangat dalam penyelesaian hingga akhir.
6. Civitas Akademik Fakultas Teknologi Industri dan Magister Informatika Universitas Islam Indonesia dalam penyelesaian penelitian.
7. Mahasiswa MI FTI UII secara umum dan khususnya konsentrasi Sains Data senior, seangkatan, dan junior yang membantu dalam penyelesaian tugas akhir.
8. Seluruh pihak yang telah membantu penulis langsung maupun tidak langsung teknik maupun non teknis.

Daftar Isi

Lembar Pengesahan Pembimbing.....	i
Lembar Pengesahan Penguji.....	ii
Abstrak.....	ii
<i>Abstract</i>	iv
Pernyataan Keaslian Tulisan.....	v
Daftar Publikasi	vi
Halaman Kontribusi.....	vii
Halaman Persembahan.....	viii
Kata Pengantar.....	iix
Daftar Isi	x
Daftar Tabel.....	xii
Daftar Gambar	xiii
Glosarium	xv
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Batasan Masalah.....	4
1.4 Tujuan Penelitian.....	4
1.5 Ruang Lingkup Penelitian	5
1.6 Hipotesis.....	5
1.7 Manfaat Penelitian.....	5
1.8 Sistematika Penulisan.....	5
BAB 2 Tinjauan Pustaka	7
2.1 Landasan Teori.....	7
2.1.1 Aspect-based Sentiment Analysis (ABSA)	7

2.1.2	Text Mining	7
2.1.3	Convolutional Neural network (CNN)	7
2.1.4	Temporal Convolutional Network (TCN).....	8
2.1.5	Gate Recurrent Unit (GRU).....	9
2.2	Kajian Pustaka.....	10
BAB 3 Metodologi.....		17
3.1	Metodologi Penelitian	17
3.1.1	Pengumpulan Data	17
3.1.2	Data Preprocessing.....	18
3.1.3	Evaluasi.....	27
BAB 4 Hasil dan Pembahasan		29
4.1	Dataset.....	29
4.2	Descriptive Analysis	32
4.3	Sentimen Multi Aspek.....	33
4.4	Preprocessing Data.....	35
4.5	Pembentukan Model ABSA.....	38
4.6	Sentimen Klasifikasi	43
4.6	Aspek Klasifikasi	47
4.6	Pengujian Model	52
BAB 5 Penutup		58
5.1	Kesimpulan	58
5.1	Saran.....	58
Daftar Pustaka.....		59

Daftar Tabel

Tabel 2.2.1 Rangkuman Tinjauan Pustaka	12
Tabel 3.1 Kategori Aspek	18
Tabel 3.2 Skenario Normalize Data.....	19
Tabel 3.3 Daftar Stopword	20
Tabel 3.4 Besar Hyperparameter	20
Tabel 4.1 Contoh Dataset Ulasan	34
Tabel 4.2 Distribusi Kelas Aspek & Sentimen	34
Tabel 4.3 Contoh Data Setelah Preprocessing	37
Tabel 4.4 Hasil Downsampling	40
Tabel 4.5 Hasil Evaluasi Pada Klasifikasi Sentimen.....	49
Tabel 4.6 Hasil Evaluasi Pada Klasifikasi Aspek.....	53
Tabel 4.7 Aspek Positif dan Negatif.....	64

Daftar Gambar

Gambar 2.1 Arsitektur CNN.....	7
Gambar 2.2 Arsitektur TCN	9
Gambar 3.1 Alur Penelitian	17
Gambar 3.2 Langkah Preprocessing	19
Gambar 3.3 Arsitektur klasifikasi sentimen model CNN.....	24
Gambar 3.4 Arsitektur klasifikasi sentimen model TCN	25
Gambar 3.5 Arsitektur klasifikasi sentimen model GRU	26
Gambar 3.6 Arsitektur klasifikasi aspek model CNN	27
Gambar 3.7 Arsitektur klasifikasi aspek model TCN.....	28
Gambar 3.8 Arsitektur klasifikasi aspek model GRU	29
Gambar 3.9. Struktur Confusion Matrix.....	31
Gambar 4.1 Scraping data ulasa	32
Gambar 4.2 Script program proses scraping data ulasan.....	35
Gambar 4.3 Contoh ulasan user.....	36
Gambar 4.4 Grafik Sentimen Per 2020-2021	37
Gambar 4.4 Grafik Sentimen Per 2020-2021	38
Gambar 4.6 Script program proses case folding.....	40
Gambar 4.7 Script program prose tokenization	41
Gambar 4.8 Script program proses normalize	41
Gambar 4.9 Script program proses stop-word	42
Gambar 4.10 Script program proses stemming.....	43
Gambar 4.11 Script program proses koneksi colab ke drive	44
Gambar 4.12 Script program proses tf-idf	44
Gambar 4.13 Script program proses pemecahan kata menjadi nilai vector.....	45
Gambar 4.14 Script program one-hot encoding.....	45
Gambar 4.15 Script program downsampling data sentimen dan aspek	45
Gambar 4.16 Script program proses data split.....	46
Gambar 4.17 Script program CNN model.....	47
Gambar 4.18 Script program TCN model	48
Gambar 4.19 Script program GRU model.....	48

Gambar 4.20 Confusion Matrix CNN.....	50
Gambar 4.21 Confusion Matrix TCN.....	51
Gambar 4.22 Confusion Matrix GRU.....	51
Gambar 4.23 Grafik Loss & Accuracy Sentiment Model CNN	52
Gambar 4.24 Grafik Loss & Accuracy Sentiment Model TCN.....	52
Gambar 4.25 Grafik Loss & Accuracy Sentiment Model GRU	53
Gambar 4.26 Confusion Matrix Klasifikasi Aspek Model CNN.....	54
Gambar 4.27 Confusion Matrix Klasifikasi Aspek Model TCN.....	55
Gambar 4.28 Confusion Matrix Klasifikasi Aspek Model GRU.....	56
Gambar 4.29 Grafik Loss dan Accuracy Klasifikasi Aspek Model CNN	57
Gambar 4.30 Grafik Loss dan Accuracy Klasifikasi Aspek Model TCN.....	57
Gambar 4.31 Grafik Loss dan Accuracy Klasifikasi Aspek Model GRU	58
Gambar 4.32 Script Program ABSA.....	59
Gambar 4.33 Hasil Klasifikasi Sentimen & Aspek	59
Gambar 4.34 Word cloud Aspek Aplikasi Positif dan Negatif.....	60
Gambar 4.35 Word cloud Aspek User Interface Positif dan Negatif	61
Gambar 4.36 Word cloud Aspek User Experience Positif dan Negatif.....	62
Gambar 4.37 Word cloud Aspek Kode OTP Positif dan Negatif.....	62
Gambar 4.38 Word cloud Aspek Kartu Vaksin Positif dan Negatif.....	63
Gambar 4.39 Word cloud Aspek Layanan Positif dan Negatif	63

Glosarium

UII	- Universitas Islam Indonesia
ABSA	- Aspect-based Sentiment Analysis
PPKM	- Pemberlakuan Pembatasan Kegiatan Masyarakat
CNN	- Convolutional Neural Network
TCN	- temporal Convolutional Network
GRU	- Gate Recurrent Unit
TF-IDF	- Term Frequency – Inverse Document Frequency
VSM	- Vector Space Model
Batch size	- Jumlah sampel yang dimasukkan kedalam network
Fitur ekstraksi	- Tahap pengambilan data dengan pengenalan pola
Epoch	- Jumlah iterasi network melihat seluruh dataset
Loss	- Nilai yang diminalkan oleh jaringan saraf
Optimizer ADAM	- Digunakan dalam mengoptimalkan kinerja model
Training	- Proses model mempelajari data

BAB 1

Pendahuluan

1.1 Latar Belakang

Aplikasi ini memiliki tujuan yang sangat penting dalam mengatasi penyebaran Covid-19 di Indonesia. Dengan mengandalkan teknologi dan partisipasi masyarakat, Pedulilindungi membantu memantau dan melacak penyebaran virus dengan lebih efektif. Pedulilindungi dirancang untuk membantu menghentikan penyebaran Covid-19 di Indonesia. Aplikasi ini memungkinkan masyarakat untuk membagikan data lokasi saat bepergian, sehingga penelusuran riwayat kontak dengan penderita Covid-19 dapat dilakukan dengan lebih efektif. Aplikasi ini pertama kali dirilis pada 28 Maret 2020 dan telah mengalami pembaruan pada 8 Februari 2022. Peningkatan aplikasi ini mencerminkan upaya untuk terus mengembangkan dan meningkatkan fungsionalitas serta keefektifannya. Dengan lebih dari 50 juta pengguna yang telah menginstal aplikasi ini, Pedulilindungi telah mendapatkan dukungan yang signifikan dari masyarakat. Hal ini menunjukkan kesadaran dan partisipasi masyarakat dalam menggunakan teknologi untuk mengatasi pandemi. Aplikasi ini menggunakan fitur bluetooth untuk merekam informasi yang diperlukan saat terjadi pertukaran data antara gadget yang terdaftar di Pedulilindungi. Dengan cara ini, aplikasi dapat mengidentifikasi dan melacak kemungkinan kontak dengan individu yang positif Covid-19. Pedulilindungi juga memberikan informasi tentang zona aman dan zona merah. Ini membantu pengguna untuk mengetahui risiko saat berada di suatu tempat tertentu dan dapat memberikan panduan bagi masyarakat dalam mengambil langkah-langkah pencegahan yang sesuai. Secara keseluruhan, Pedulilindungi adalah contoh bagaimana teknologi dapat dimanfaatkan untuk memberikan kontribusi dalam menghadapi tantangan global seperti pandemi Covid-19. Aplikasi ini menunjukkan upaya untuk menggabungkan partisipasi masyarakat dengan teknologi dalam rangka mengurangi penyebaran virus dan melindungi kesehatan publik.

Aplikasi Pedulilindungi memiliki peran yang sangat penting selama masa pandemi, terutama dalam situasi pembatasan kegiatan masyarakat (PPKM). Aplikasi ini tidak hanya membantu dalam melacak penyebaran Covid-19, tetapi juga memiliki fungsi lain yang berguna bagi pelaku perjalanan di Indonesia. Selain mengatasi penyebaran virus, Pedulilindungi juga digunakan untuk menyimpan dokumen persyaratan perjalanan secara

digital. Ini dapat mencakup dokumen seperti sertifikat vaksinasi atau data kesehatan pelaku perjalanan. Dengan memiliki fungsi ini, aplikasi membantu mempermudah proses perjalanan dan mematuhi protokol kesehatan. Aplikasi ini merupakan salah satu upaya pemerintah Indonesia untuk memberikan layanan yang berkualitas, efisien, dan adil secara sosial kepada masyarakat. Dalam konteks PPKM dan situasi pandemi, pemerintah menggunakan teknologi untuk menjaga kebutuhan publik dan mengendalikan penyebaran virus. Ulasan dan umpan balik yang dibagikan oleh pengguna melalui Pedulilindungi dapat menjadi sumber data yang berharga. Data ini dapat dimanfaatkan untuk mengukur kepuasan dan merespons masukan masyarakat terkait layanan yang diberikan melalui aplikasi. Sentiment Analysis atau analisis sentimen menjadi alat penting dalam mengukur pandangan dan perasaan masyarakat terhadap layanan atau produk tertentu. Dengan menganalisis ulasan dan umpan balik yang diberikan oleh pengguna, pemerintah dapat memahami persepsi publik dan membuat perbaikan yang diperlukan. Penelitian ini berfokus pada Aspect-Based Sentiment Analysis (ABSA) pada ulasan aplikasi Pedulilindungi. ABSA memungkinkan untuk menganalisis sentimen berdasarkan aspek-aspek tertentu yang relevan dengan layanan. Dalam penelitian ini, ABSA digunakan untuk meningkatkan kualitas aplikasi Pedulilindungi dengan memahami pandangan masyarakat terhadap aspek-aspek tertentu dari aplikasi. Sejumlah penelitian sebelumnya telah melakukan ABSA pada domain yang berbeda. Beberapa penelitian menggunakan metode POS Tagger untuk ekstraksi aspek, sementara yang lain menggabungkan teknik klasifikasi dengan proses ekstraksi. Penelitian ini tampaknya tidak menggunakan POS Tagger, kemungkinan karena pertimbangan sumber daya. Secara keseluruhan, aplikasi Pedulilindungi tidak hanya menjadi alat penting dalam mengatasi penyebaran Covid-19, tetapi juga memiliki potensi untuk memberikan layanan yang berkualitas dan merespons masukan masyarakat melalui analisis sentimen berbasis aspek. Dengan menggabungkan teknologi dengan pemahaman akan sentimen masyarakat, aplikasi ini dapat terus dikembangkan dan ditingkatkan.

Peningkatan Desain Produk (Jayant Bhargav., 2019) Penelitian ini fokus pada penggunaan ABSA dalam meningkatkan desain produk. Penelitian tersebut menganalisis ulasan konsumen tentang produk laptop untuk mendapatkan wawasan tentang sentimen terhadap aspek-aspek tertentu dari produk. Perbandingan Arsitektur Deep Learning (Shweta Dhabekar., 2021) Penelitian ini membandingkan tiga arsitektur deep learning, yaitu CNN, RNN, dan LSTM, untuk tugas ABSA. Hasil penelitian menunjukkan bahwa

model LSTM memberikan akurasi terbaik. ABSA pada Ulasan Data Restoran Berbahasa Indonesia (Putri Rizki Amalia & Edi Winarko) Penelitian ini menerapkan ABSA pada ulasan data restoran berbahasa Indonesia dengan menggunakan kombinasi metode BERT-CNN, ELMo-CNN, dan Word2vec-CNN. Hasil terbaik diperoleh dari model ELMo-CNN dengan nilai micro-average precision 0.88%, micro average recall 84%, dan f1-score 0.86%. Untuk klasifikasi sentiment, hasil terbaik diperoleh dari model BERT-CNN dengan nilai precision 0.89%, recall 0.86, dan f1-score 0.91. Melalui penelitian-penelitian ini, dapat dilihat bahwa ABSA dapat diterapkan pada berbagai jenis data ulasan dan produk. Berbagai metode dan arsitektur deep learning digunakan untuk mencapai hasil yang lebih baik dalam menganalisis sentiment dan aspek-aspek tertentu dari ulasan pengguna.

ABSA pada Ulasan Restoran Berbahasa Albanian (Majlinda Axhiu & Azir Aliu., 2020). Penelitian ini fokus pada klasifikasi level aspek dan sentiment pada 2500 ulasan restoran berbahasa Albanian. Penelitian ini menerapkan metode Non-Negative Matrix Factorization (NMF) pada tugas ABSA. ABSA pada Ulasan Hotel dengan Metode Machine Learning (I Putu Ananda Miarta Utama et al., 2021):** Penelitian ini menerapkan empat arsitektur machine learning (random forest, svm, hybrid classifier, dan naïve bayes) pada dataset ulasan hotel berbahasa Inggris. Model hybrid classifier berhasil mencapai rata-rata akurasi sebesar 84%. Algoritma Deep Learning pada Sentiment Analysis (Prasetyo Wahyu Adi Wianto., 2018). Penelitian ini menerapkan metode Convolutional Neural Network (CNN) pada sentiment analysis. TCN dalam Teks Klasifikasi (Shaojie et al., 2018) Penelitian ini menggunakan metode Temporal Convolutional Network (TCN) pada tugas teks klasifikasi, mencapai tingkat akurasi yang tinggi pada dataset task Peen Treebank. Analisis Sentiment dengan RNN dan LSTM (Oni Harnantyo., 2019). Penelitian ini berhasil menerapkan dua metode deep learning, yaitu Recurrent Neural Network (RNN) dan Long Short-Term Memory (LSTM), pada analisis sentiment. LSTM dalam Sentiment Analysis Multi-Class (Yulia Asatari et al., 2021) Penelitian ini menerapkan metode Long Short-Term Memory (LSTM) dalam sentiment analysis multi-class. GRU dalam Teks Klasifikasi (Faiyaz et al., 2015). Penelitian ini berhasil menerapkan arsitektur Gated Recurrent Unit (GRU) dalam menyelesaikan permasalahan teks klasifikasi.

Selain itu, Anda juga menggambarkan tentang pentingnya ABSA pada domain ulasan aplikasi pemerintah yang masih kurang dijelajahi. Anda menyebutkan bahwa pendekatan Convolutional Neural Network (CNN), Temporal Convolutional Network (TCN), dan Gated Recurrent Unit (GRU) digunakan dalam penelitian Anda untuk

meningkatkan kinerja ABSA pada domain ulasan aplikasi pemerintah. Semua penelitian ini menunjukkan bahwa ABSA merupakan pendekatan yang berguna untuk menganalisis sentimen dan aspek-aspek tertentu dari ulasan dalam berbagai domain. Dengan menggunakan berbagai metode dan algoritma, penelitian-penelitian ini membantu dalam memahami perspektif pengguna terhadap produk atau layanan yang ditinjau.

1.2 Rumusan Masalah

Berdasarkan latar belakang masalah untuk membuat ABSA menggunakan data ulasan pedulilindungi dengan ribuan dataset, masalah yang menjadi pokok penelitian yaitu:

- a. Menganalisis ABSA pada Domain Ulasan Aplikasi Tracking COVID-19 dengan deep Learning?
- b. Mengevaluasi Klasifikasi Sentimen dan Klasifikasi Aspek pada Domain Ulasan Aplikasi Tracking COVID-19 dengan Deep Learning?

1.3 Batasan Masalah

Berikut adalah batasan permasalahan yang akan dibahas agar tidak menyimpang dari tujuan penelitian yaitu:

- a. Dataset yang digunakan adalah data ulasan aplikasi sebanyak 23.183 data ulasan per 2020 maret-desember dan 2021 januari-agustus
- b. Aspek yang digunakan adalah aplikasi, user interface, user experience, kode OTP (One time password), unduh sertifikat vaccine, dan bukti akses layanan publik.
- c. Polaritas sentimen yang digunakan adalah positif dan negatif.

1.4 Tujuan Penelitian

Tujuan dilakukan penelitian ini adalah menganalisis hasil metode terbaik pada klasifikasi aspek dan klasifikasi sentimen pada ulasan aplikasi pedulilingi menggunakan deep learning.

1.5 Ruang Lingkup Penelitian

Penelitian ini dibatasi pada dataset ulasan aplikasi pedulilindungi dengan unit aspek yang ditentukan berdasarkan word Clouds menampilkan frekuensi kata yang terdapat pada kumpulan dataset. Selanjutnya pelabelan dataset berdasarkan rating dimana skala (1-3) mengungkapkan sentimen negatif terhadap aspek (4-5) mengungkapkan sentimen positif. Setelah itu proses klasifikasi dilakukan menggunakan metode CNN, TCN, dan GRU.

1.6 Hipotesis

1. Teknik pelabelan berdasarkan rating user
2. Penyelesaian masalah pada kasus aspect-basedsentimen dilakukan dengan algoritma CNN, TCN, dan GRU.

1.7 Manfaat Penelitian

Manfaat yang dihasilkan dari penelitian ini adalah:

- a. Bagi para developer, penelitian ini dapat membantu dalam mengetahui tanggap keluhan pengguna terhadap aplikasi pedulilindungi.
- b. Penelitian ini dapat dijadikan referensi untuk penelitian lain pada kasus aspek based klasifikasi yang lebih spesifik pada teks mining.

1.8 Sistematika Penulisan

Gambaran umum sistematika penulisan pada tesis ini terdiri dari lima bab yaitu:

BAB I Pendahuluan

Bagian ini berisi latar belakang penulisan, batasan masalah, tujuan penelitian, ruang lingkup penelitian, hipotesis, manfaat penelitian, dan sistematika penulisan.

BAB II Tinjauan Pustaka

Bagian ini membahas tinjauan pustaka yang berisi landasan teori pendukung untuk memecahkan masalah. Teori-teori yang terkait ABSA, text mining, algoritma CNN, TCN, dan algoritma GRU yang relevan dalam penelitian.

BAB III Metodologi

Bab ini membahas tentang langkah-langkah penelitian dan pembuatan model yang merupakan inti dari pembahasan dalam penyelesaian masalah yang diteliti.

BAB IV Hasil dan Pembahasan

Bab ini membahas tentang proses pengumpulan data hingga tahap hasil yang diperoleh pada tiga model deep learning.

BAB V Penutup

Bab ini berisi kesimpulan dan saran dari hasil yang dilakukan.

BAB 2

Tinjauan Pustaka

2.1. Landasan Teori

2.1.1. *Aspect-based Sentiment Analysis (ABSA)*

Analisis Sentimen Berbasis Aspek (ABSA). ABSA merupakan pendekatan yang lebih mendalam dalam menganalisis sentimen suatu teks dengan fokus pada aspek-aspek yang ada dalam teks tersebut. Dalam ABSA, aspek-aspek tertentu yang ada dalam teks diekstraksi dan kemudian dianalisis sentimennya secara terpisah untuk setiap aspek tersebut. Selain itu, sentimen keseluruhan dari teks juga dapat dihasilkan melalui klasifikasi sentimen dari semua aspek yang diekstraksi.

Dalam penelitian ABSA yang dilakukan oleh Gu et al. pada tahun 2018, peneliti menghindari penggunaan identifikasi kelas kata karena dianggap memerlukan sumber daya yang besar. Sebagai alternatif, mereka mungkin menggunakan pendekatan lain, seperti metode berbasis lexicon, untuk mengekstraksi aspek-aspek dari teks sebelum menganalisis sentimen. Studi yang dilakukan oleh Omar Alqalyouti, Azza Abdel Monem, & Khaled Shaalan pada tahun 2019, terlihat menggunakan lexicon untuk mengekstrak aspek-aspek sebelum melakukan analisis sentimen. Mereka melakukan klasifikasi terhadap sejumlah besar data (7.345 data) untuk memahami sentimen dari masing-masing aspek yang ditemukan.

ABSA dapat diaplikasikan dalam berbagai domain, termasuk ulasan produk, media sosial, ulasan hotel, dan ulasan restoran. Pendekatan ABSA dapat dibagi menjadi tiga level klasifikasi: tingkat dokumen, tingkat kalimat, dan tingkat entitas. Pada tingkat dokumen, ABSA berfokus pada sentimen keseluruhan dari teks. Pada tingkat kalimat, setiap kalimat dalam teks dianalisis untuk sentimennya terkait dengan aspek-aspek yang ada. Pada tingkat entitas, ABSA berfokus pada sentimen aspek tertentu yang ada dalam teks. Tujuan utama dari analisis sentimen berbasis aspek adalah untuk mengidentifikasi polaritas sentimen yang bisa berupa positif, negatif, atau netral terkait dengan aspek-aspek yang ada dalam teks. Pendekatan ini membantu dalam memahami sentimen yang lebih halus dan spesifik dalam teks, memberikan wawasan yang lebih dalam mengenai bagaimana orang merasakan dan menilai berbagai aspek.

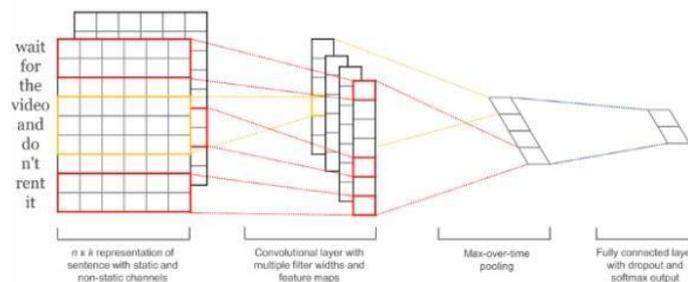
2.1.2. Text Mining

Text mining merupakan suatu proses pengolahan data teks yang bertujuan untuk menggali informasi dan pemahaman dari teks yang tidak terstruktur. Proses ini melibatkan penggunaan perangkat lunak dan teknik analisis statistik atau komputasional untuk mengidentifikasi pola, relasi, konsep, topik, dan atribut lainnya dalam data teks.

2.1.3. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan salah satu jenis algoritma Deep Learning yang mampu dalam mengatasi permasalahan seperti object detection, image classification, maupun video classification. Arsitektur CNN telah banyak digunakan pada masalah image classification (Y. Zhang & B. Wallace., 2015). Meskipun cnn telah banyak diaplikasikan pada permasalahan image classification cnn juga mampu mengatasi pada permasalahan data teks (Y. Kim., 2014). Dalam mengatasi permasalahan pada data teks membutuhkan penambahan embedding layer yang memetakan indeks kata kosakata dalam representasi vector (Moch. Ari Nasichuddin., 2017).

Convolutional Neural Network (CNN) adalah salah satu jenis algoritma deep learning yang dapat menangani berbagai masalah seperti deteksi objek, klasifikasi gambar, dan klasifikasi video. CNN biasanya banyak digunakan untuk data gambar. Meskipun banyak diaplikasikan pada klasifikasi gambar, CNN juga efektif dalam menangani masalah teks (Y. Zhang & B. Wallace., 2015).. CNN terdiri dari beberapa lapisan (layer). Lapisan pertama mengkonversi kata-kata menjadi vektor dengan dimensi rendah (low-dimensional vector). Lapisan kedua melakukan operasi konvolusi dengan menggunakan berbagai ukuran filter (multiple filter size). Hasilnya kemudian dipooling (max-pool) untuk menghasilkan fitur panjang (long feature vector). CNN juga menerapkan dropout regularization pada lapisan fully connected, dan hasilnya diklasifikasikan menggunakan lapisan ReLu (Naquitasia et al., 2022).. Ilustrasi CNN untuk klasifikasi teks dapat dilihat pada Gambar 2.



Gambar 2.1 Arsitektur CNN

2.1.4. Temporal Convolutional Network (TCN)

TCN adalah arsitektur deep learning menggunakan neural network yang mampu mengatasi permasalahan data sequential menggunakan 1D fully-convolutional network pada teks klasifikasi (Shaoji et al., 2018). Berbeda dengan CNN, TCN memiliki konvolusi arsitektur bersifat kausal, yaitu tidak ada informasi kebocoran dari masa depan ke masa lalu, dan arsitektur dapat mengambil urutan berapapun panjangnya serta memetakan urutan output dengan panjang yang sama (Long et al., 2015). Gambar 2.2 menunjukkan arsitektur TCN yang terdiri dari:

1. *Sequence modelling* sebagai tugas pemodelan urutan *input* yang diinginkan x_0, \dots, x_t dan prediksi *output* yang sesuai y_0, \dots, y_t pada setiap waktu. Kendala utama adalah untuk prediksi keluaran y_t selama beberapa waktu (t) menggunakan input yang diamati sebelumnya: x_0, \dots, x_t secara formal urutan pemodelan jaringan setiap fungsi $f : x^{t+1} \rightarrow y^{t+1}$ itu menghasilkan pemetaan:

$$\hat{y}_0, \dots, \hat{y}_t = f(x_0, \dots, x_t) \quad (1)$$

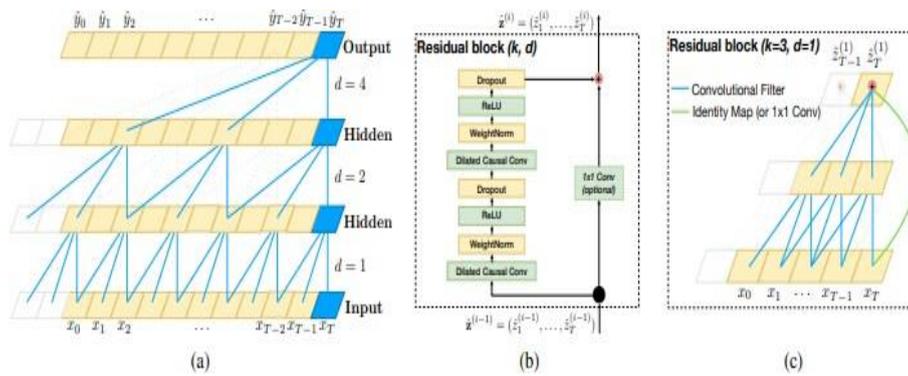
Jika memenuhi batas kausal bahwa y_t hanya bergantung pada x_0, \dots, x_t dan bukan pada *input* masa depan x_{t+1}, \dots, x_T . Tujuannya untuk menemukan jaringan f yang meminimalkan beberapa kerugian yang diharapkan antara *output* aktual dan prediksi, $L(y_0, \dots, y_t, f(x_0, \dots, x_t))$, di mana urutan dan keluaran berdasarkan distribusi.

2. *Causal convolutionions* untuk mencapai poin pertama, TCN menggunakan arsitektur jaringan 1D *fully-convolutional network* (FCN) [23] di mana tiap *hidden layer* mempunyai panjang yang sama dengan *input layer* dan panjang *padding* 0 (*kernel size* – 1) ditambah untuk menjaga *hidden* berikutnya yang memiliki panjang sama dengan sebelumnya. Untuk mencapai poin kedua, TCN menggunakan *causal convolutions* di mana *output* pada waktu (t) di konvolusi hanya dengan elemen waktu (t) dan sebelumnya pada *layer* tersembunyi.

Sederhananya: TCN = 1D FCN + konvolusi kausal.

3. *Dilated convolutions* untuk melihat kembali sejarah dengan ukuran *linear* dalam jaringan. Secara lebih formal, untuk 1-D panjang input $X \in R^n$ dan *filter* $f : \{0, \dots, k - 1\} \rightarrow R$, konvolusi yang melebar operasi F pada elemen S yang didefinisikan sebagai:

$$f(s) = (x *_d f)(s) = \sum_{t=0}^{k-1} f(i) \cdot X_{s-d \cdot i} \quad (2)$$



Gambar 2.2 Arsitektur TCN

Dalam konteks yang Anda sebutkan, sepertinya Anda sedang menjelaskan beberapa konsep yang terkait dengan arsitektur TCN (Temporal Convolutional Network) dan cara kerjanya. Mari kita bahas setiap poin yang Anda jelaskan:

(a) **Konvolusi Melebar dengan Dilatasi (Dilated Convolution):** Konvolusi melebar adalah konsep dalam konvolusi temporal di mana filter bergerak melintasi input dengan langkah-langkah yang lebih besar dari 1. Faktor dilatasi (d) mengatur seberapa banyak nilai-nilai di antara elemen-elemen dalam filter. Dengan faktor dilatasi yang berbeda, filter dapat "melihat" dan menangkap pola yang lebih luas dalam data temporal. Misalnya, dengan $d = 1$, filter melihat data dalam urutan normal. Dengan $d = 2$, filter melihat setiap elemen kedua dalam urutan, dan seterusnya.

(b) **Residual Connection dengan Konvolusi 1x1:** Residual connection atau skip connection adalah elemen penting dalam arsitektur TCN. Konvolusi 1x1 digunakan dalam residual connection untuk menghubungkan input langsung ke output. Ini membantu dalam mengatasi masalah gradien yang melemah selama pelatihan dalam jaringan yang dalam atau dalam kasus jaringan panjang. Jika input dan output berbeda dalam dimensi, konvolusi 1x1 digunakan untuk mengubah dimensi input agar sesuai dengan output.

(c) **Hubungan Fungsi Residu dan Pemetaan Identitas:** Dalam arsitektur TCN, ada penggunaan filter yang diterapkan pada fungsi residu. Filter ini membantu dalam menangkap pola-pola temporal dalam data. Selain itu, ada pemetaan identitas yang digunakan untuk memastikan bahwa informasi asli dari input tetap ada dalam output. Ini penting untuk menghindari kehilangan informasi yang signifikan saat memproses data melalui lapisan-lapisan konvolusi.

Secara keseluruhan, arsitektur TCN menggabungkan konsep konvolusi melebar, residual connection, dan pemetaan identitas untuk membangun jaringan yang dapat menangkap pola-pola temporal dalam data dengan efektif. Ini umumnya digunakan untuk tugas yang melibatkan urutan data, seperti tugas klasifikasi atau analisis sentimen berbasis waktu.

2.1.5. Gate Recurrent Unit (GRU)

GRU merupakan sebuah pengembangan dari model LSTM yang dapat mengatasi permasalahan data panjang dengan arsitektur yang lebih sederhana. Berbeda dengan LSTM yang memiliki tiga jenis parameter, GRU mempunyai sedikit parameter (update gate dan reset gate) sehingga pelatihan dan konvergensinya lebih cepat daripada LSTM. Dimana update state (r_t) merepresentasikan berapa banyak informasi yang tersimpan, sementara pada reset gate (z_t) berfungsi untuk menentukan banyaknya informasi yang tidak diperlukan. kandidat aktivasi $\hat{h}(t)$ dihitung seperti recurrent unit menyimpan informasi sebelum (r_t) digunakan, selanjutnya hidden state (h_t) memori akhir yang akan disimpan. Representasi matematis pada model dasar GRU ditunjukkan pada:

$$r_t = \sigma(W_r[h_{t-1}, x_t] + b_r) \quad (3)$$

$$z_t = \sigma(W_z[h_{t-1}, x_t] + b_z) \quad (4)$$

$$\hat{h}(t) = \tanh(W_h[r_t * h_{t-1}, x_t] + b_h) \quad (5)$$

$$h_t = (1 - z_t) * h_{t-1} + z_t * \hat{h}(t) \quad (6)$$

2.2. Kajian Pustaka

Aspect Based Sentiment Analysis (ABSA) merupakan teknik analisis sentimen yang memungkinkan untuk mengatasi permasalahan analisis sentimen berdasarkan kategori aspek dalam suatu dokumen. ABSA bertujuan untuk mengklasifikasikan ulasan ke dalam kelas positif atau negatif berdasarkan kategori aspek yang relevan (Liu, 2015). Teknik ini telah diaplikasikan dalam berbagai penelitian pada domain ulasan hotel, restoran, film, produk, dan lebih lanjut dalam tingkat aspek tertentu. Sebagai contoh, beberapa penelitian sebelumnya telah menerapkan ABSA pada ulasan restoran dengan melakukan scraping data ulasan melalui situs seperti TripAdvisor (Putri Rizki Amalia & Edi Winarko, 2021) dan ulasan hotel di Bali pada TripAdvisor dengan menggunakan model Recursive Neural Tensor Network (Prameswari et al., 2018). Selain itu, ABSA juga telah diaplikasikan pada

ulasan produk seperti pada media sosial dan aplikasi pintar, seperti ulasan di Tokopedia melalui Google Play Store (Sabrah Ailiyya, 2020). Proses ekstraksi dalam ABSA dapat bervariasi, termasuk langkah-langkah seperti aspect extraction (ekstraksi aspek) sebelum klasifikasi sentimen, yang melibatkan pengambilan aspek yang relevan dari ulasan (Shinta Prima Astuti, 2020) atau menggunakan pendekatan berbasis lexicon seperti Aspect Term Extraction (ATE) (Farza Nurifan et al., 2019) atau SVM-CRF (Forhad An Naim, 2020). Penelitian ini fokus pada penerapan teknik deep learning untuk ABSA dengan menggunakan data ulasan aplikasi seluler pemerintah "PeduliLindungi" dari Google Play Store. Data ini telah dilabelkan berdasarkan rating yang diberikan oleh pengguna terhadap layanan tersebut. Penelitian ini mengadopsi kelas aspek yang termasuk aplikasi, user interface, user experience, kode OTP, unduh sertifikat vaksin, dan akses layanan publik. Dalam penelitian ini, dilakukan dua sub-tugas utama yaitu ekstraksi aspek dan klasifikasi sentimen menggunakan pendekatan deep learning seperti CNN, TCN, dan GRU. Tabel 2.2.1 pada rangkuman tinjauan pustaka akan menampilkan hasil-hasil yang relevan terkait dengan pendekatan dan metode yang digunakan dalam penelitian ini.

Tabel 2.2.1 Rangkuman Tinjauan Pustaka.

No	Nama	Judul	Domain	Label	Metode	Hasil
1.	(Bilal Yacoub Siyam., 2018)	Deep Learning for Aspect-Based Sentiment Analysis of Government Mobile Apps Reviews	Government Mobile Apps Reviews	Sentimen: Positif, negative	CNN, Glove	Accuracy Score: 89.42% F-measure: 9.23%
2.	(Omar Harb Abdelkharim Alqaryouti., 2017)	Aspect-Based Sentiment Analysis for Government Smart Applications Customers' Reviews	Government Smart Applications Reviews	Sentiment: Positif, negative	Machine Learning	Accuracy score: 86.83% Precision: 75.49% Recall: 70.64% F-measure: 72.98%
3.	(Jiaxin Huang et al., 2018)	Weakly-Supervised Aspect_based Sentiment Analysis via Joint Aspect_Sentiment Topic Embedding	Reviews Restaurant	Sentiment: Positif, negative	CNN	Accuracy score: 81.96% Precision: 82.85% Recall: 78.11% F-measure: 79.44%

			Product Reviews Laptop	Sentiment: Positif, negative	CNN	Accuracy score: 74.59% Precision: 74.69% Recall: 74.65% F-1 Score: 74.59%
4.	(Shweta Dhabekar et al., 2021)	Implementation of Deep Learning Based Sentiment Classification and Product Aspect Analysis	Product Reviews	Sentimen: Positif, negative	CNN, RNN, LSTM	Negative: Precision: 0.87% Recall: 0.82% F1-Score: 0.84% Positif: Precision: 0.94% Recall: 0.96% F1-Score: 0.95% Average:

						Precision: 0.92% Recall: 0.92% F1-Score: 0.92%
5.	(Putri Rizki Amalia, & Edi Winarko., 2021)	Aspect_Based Sentiment Analysis on Indonesian Restaurant Review Using a Combination on Convolutional Neural Network and Contextualized Word Embedding	Reviews Restaurant	Sentiment: Positif, negative	BERT-CNN, ELMo-CNN, dan Word2vec_CN N	Accuracy score: Precision: 0.88% Recall: 0.84% F1-Score: 0.86%
6.	(Majlinda, Azir Aliu., 2020)	Semi_SUpervised Aspect-Based Sentiment Analysis On Albanian Restaurant Reviews	Restaurant Reviews	Sentiment: Positif, negative	Semi-Supervised Non-Negative Matix Factoriation (NMF)	Accurac Score: 0.81% Precision positif polarity: 0.82% Recall Positive polarity: 0.85% Precision Negatif polarity: 0.80% Recall Negative polarity: 0.76%
7.	(I Putu	Multi-Aspect Sentiment	Hotel Reviews	Sentiment:	Machine	Accuracy Score: 84%

	Ananda Miarta et al., 2021)	Analysis Hotel Review Using RF, SVM, and Naïve Bayes based Hybrid Classifier)		Positif, negative	Learning	Hybrid Classifier Accuracy Score: 82.4% Nive Bayes Accuracy Score: 82.2% Random Forest Accuracy Score: 81% SVM
8.	(D. Ekawati, & M. L. Khodra., 2017)	Aspect-based Sentiment Analysis for Indonesian Restaurant Reviews	Reviews Restaurant	Sentiment: Positif, negative	Word2vec model Neural Network CBOW, dan Glove	F-1 Score: Aspect Extraction: 0.793% Aspect categorization: 0.823% Sentiment Classification: 0.642%
9.	(Salsabila Rahma Yustihan et al., 2021)	Analisis Sentimen berbasis Aspek terhadap Data Ulasan Rumah Makan menggunakan Metode Support Vector Machine	Rumah makan Reviews	Sentiment: Positif, negative	SVM	Accuracy score: 0.88% dan 0.86% Precision: 0.94% dan 0.86% Recall: 0.6% dan

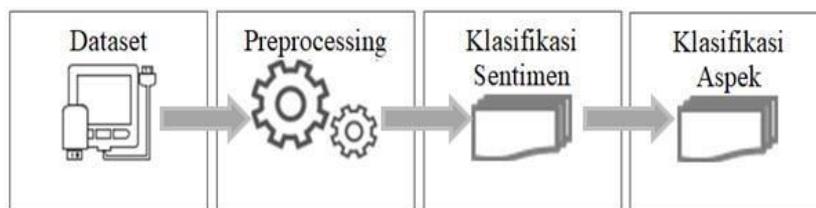
						0.98% f-measure: 0.73% dn 0.92%
10.	(Sabrah Ailiyya., 2020)	Analisis Sentimen Berbasis Aspek Pada Ulasan Aplikasi Tokopedia Menggunakan Support Vector Machine	Product Reviews	Sentiment: Positif, negative	Support Vector Machine (SVM)	Accuracy score Klasifikasi Sentimen sebesar 69.2% dan Accuracy Score Aspek 74.2

BAB 3

Metodologi

2.1 Metode Penelitian

Proses klasifikasi sentiment berbasis aspek dapat melibatkan berbagai langkah yang bervariasi tergantung pada pendekatan yang digunakan dalam setiap penelitian. Dalam konteks studi ini, kategori aspek yang digunakan merujuk pada penelitian sebelumnya (Omar Harb Abdelkarim Al Qaryouti, 2017) dan (Omar Al Qaryouti et al., 2019), dengan penambahan beberapa aspek tambahan. Namun, proses ekstraksi sentimen tidak mengandalkan lexicon karena adanya pembatasan bahasa atau karakteristik bahasa yang digunakan. Gambar 3.1 menampilkan diagram alur penelitian yang menggambarkan langkah-langkah yang dilakukan dalam proses klasifikasi sentiment berbasis aspek. Diagram ini memberikan gambaran visual tentang bagaimana setiap tahap berhubungan satu sama lain dan bagaimana alur kerja keseluruhan penelitian dilakukan.



Gambar 3.1 Alur Penelitian

2.1.1 Pengumpulan Data

Data ulasan diambil dari situs Google Play Store menggunakan teknik web scraping. Library Python digunakan untuk mengotomatisasi proses pengambilan data dari halaman ulasan aplikasi. Data yang berhasil diambil kemudian disimpan dalam format CSV (Comma-Separated Values), yang merupakan format yang umum digunakan untuk menyimpan data tabular. Data ulasan diberi label berdasarkan rating yang diberikan oleh pengguna terhadap kepuasan layanan. Pengelompokan ini dilakukan dengan mengadopsi klasifikasi dua kelas aspek yang telah digunakan dalam penelitian sebelumnya. Pola sentimen dalam ulasan diklasifikasikan berdasarkan rating yang diberikan oleh pengguna. Rating 1-3 dianggap sebagai sentimen negatif, sedangkan rating 4-5 dianggap sebagai sentimen positif. Rating 3 secara khusus dianggap sebagai polaritas negatif. Dalam analisis ini, Anda merujuk pada klasifikasi aspek yang telah diadopsi dari penelitian sebelumnya.

Ini berarti penelitian ini fokus pada aspek-aspek yang telah ditentukan sebelumnya dan mengidentifikasi sentimen yang terkait dengan aspek-aspek tersebut. Pengambilan polaritas sentimen dari rating ulasan memberikan gambaran tentang bagaimana pengguna merasakan layanan. Rating yang lebih rendah cenderung menunjukkan ketidakpuasan, sedangkan rating yang lebih tinggi menunjukkan kepuasan rating 3 dianggap sebagai polaritas negatif karena ulasan dengan rating ini cenderung lebih spesifik ke arah negatif. Ini adalah pendekatan yang dapat diambil dalam analisis sentimen, tergantung pada konteks data.

Tabel 3.1 kategori Aspek

	Kategori Aspect	Description
ASPECT	Aplikasi	Aspek ini merujuk pada kegunaan dan kemampuan dari app tracking covid-19
	User Interface	Aspek ini menyampaikan fungsionalitas fitur antarmuka pengguna
	User experience	Aspek ini merujuk pada pengalaman pengguna dalam mengaplikasikan perangkat lunak
	Kode OTP	Aspek ini terkait dengan kode verifikasi dalam membuat akun pedulilindungi
	Akses Sertifikat Vaksin	Unduh/Cek sertifikat vaksin apabila telah melakukan dosis vaksin
	Bukti Akses Layanan Publik	Aspek ini merujuk pada pemenuhan asas pelayanan publik (Kepentingan umum, keseimbangan hak, keprofesionalan dan partisipasi terhadap tanggap keluhan)

2.1.2 Data Preprocessing

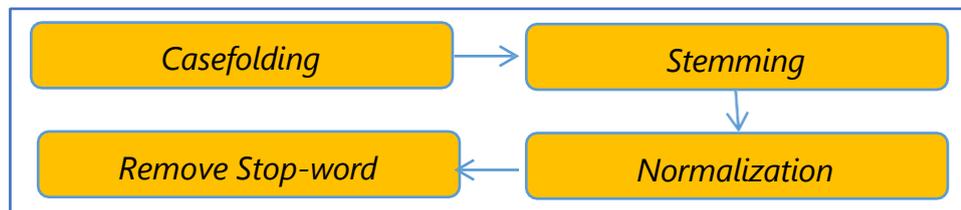
Preprocessing merupakan tahap penting dalam pengolahan data teks, terutama dalam proses text mining, sebelum melakukan proses klasifikasi. Tujuannya adalah untuk mengurangi noise dan mempersiapkan data teks agar lebih terstruktur dan sesuai untuk analisis. Proses preprocessing pada penelitian ini meliputi beberapa tahapan seperti yang dijelaskan di bawah ini:

1. Case Folding: Tidak semua dokumen teks memiliki konsistensi dalam penggunaan huruf kapital. Untuk itu, tahap case folding dilakukan untuk menyeragamkan semua

huruf menjadi huruf kecil atau mengkonversi seluruh teks dalam dokumen menjadi bentuk standar. Hal ini memungkinkan untuk menghindari perbedaan hasil dalam pencarian informasi akibat variasi huruf besar dan kecil. Misalnya, teks "SERTIFIKAT VAKSIN", "Sertifikat Vaksin", dan "sertifikat vaksin" akan diubah menjadi "sertifikat vaksin".

2. **Stemming:** Tahap stemming berfungsi untuk menghilangkan imbuhan atau mengubah kata menjadi bentuk dasarnya. Tujuan utama dari stemming adalah untuk memperkecil indeks kata tanpa menghilangkan makna dari kata tersebut. Misalnya, kata "membantu" dapat diubah menjadi kata dasar "bantu", tetapi kata "unduh" dalam konteks "unduh kartu vaksin" tidak diubah karena sudah merupakan bentuk dasar.
3. **Normalization:** Normalisasi dilakukan untuk mengubah kata yang tidak baku menjadi bentuk baku. Tujuannya adalah untuk menyamakan variasi kata dengan makna yang sama. Misalnya, variasi kata yang sama dalam konteks yang berbeda akan diseragamkan menjadi bentuk yang konsisten, seperti "unduh" menjadi "unduh".
4. **Remove Stop-Word:** Stop-words adalah kata-kata umum yang sering muncul dalam bahasa tetapi tidak memberikan kontribusi signifikan dalam analisis teks. Tahap ini melibatkan penghapusan kata-kata penghubung atau stop-words dari teks, seperti "yang", "di", "ke", dan lainnya. Hal ini membantu untuk menyederhanakan teks dan memfokuskan analisis pada kata-kata yang lebih informatif.

Dengan menjalankan serangkaian tahapan preprocessing ini, data teks akan lebih bersih dan terstruktur, serta lebih siap untuk digunakan dalam proses klasifikasi sentimen berbasis aspek pada penelitian ini. Ini membantu meminimalkan gangguan atau noise yang dapat memengaruhi hasil analisis.



Gambar 3.2 Langkah Preprocessing

Langkah-langkah selanjutnya dalam pra-pemrosesan teks adalah menghilangkan simbol, tanda baca, atau karakter selain huruf. Hal ini dilakukan untuk membersihkan teks dari elemen yang tidak diperlukan dan memastikan bahwa hanya kata-kata yang relevan yang dianalisis dalam proses klasifikasi. Untuk melakukan ini, fungsi regex (regular expression) digunakan untuk mengidentifikasi dan menghapus karakter yang tidak diinginkan. Setelah menghilangkan karakter yang tidak diinginkan, langkah berikutnya adalah mengubah semua huruf dalam teks menjadi huruf kecil. Ini dilakukan untuk memastikan konsistensi dalam teks sehingga kata yang sama dengan huruf besar atau kecil akan dianggap sama dalam proses klasifikasi. Fungsi "lower" digunakan untuk mengubah huruf-huruf dalam teks menjadi huruf kecil. Selanjutnya, tahap normalisasi dilakukan menggunakan base

dictionary. Proses ini bertujuan untuk menyeragamkan kata-kata yang memiliki makna ganda atau variasi ejaan dalam teks. Contohnya, dalam bahasa Indonesia terdapat kata-kata yang dapat memiliki variasi ejaan atau makna tergantung pada konteksnya. Dengan menggunakan base dictionary, kata-kata ini dapat diseragamkan menjadi bentuk yang lebih umum atau konsisten sehingga tidak menimbulkan ambiguitas dalam analisis. Tabel 3.2 mungkin berisi contoh kata-kata yang diseragamkan melalui proses normalisasi dengan menggunakan base dictionary. Dengan melihat contoh tersebut, pembaca dapat memahami bagaimana proses ini membantu untuk memperjelas arti dari kata-kata yang memiliki variasi makna atau ejaan dalam teks ulasan.

Tabel 3.2 Skenario Normalization Data

Text	Normalization
Tdk	Tidak
Gak	Enggak
Blm	Belum
Paksin	Vaksin
Sertivikat	Sertifikat
Sdh	Sudah
Donlod	Download

Setelah proses normalisasi, langkah selanjutnya adalah menghapus stop-word. Stop-word adalah kata-kata umum yang sering muncul dalam bahasa tetapi tidak memiliki kontribusi signifikan dalam analisis teks, seperti kata penghubung dan kata-kata seru. Tujuannya adalah untuk membersihkan teks dari elemen yang tidak memiliki arti khusus dan tidak memberikan informasi yang berarti. Pada penelitian ini, penghapusan stop-word dilakukan menggunakan library "nltk" (Natural Language Toolkit) dalam bahasa pemrograman Python. Selain itu, ada juga langkah untuk mentransformasi kata "tidak" atau "bukan" guna menghilangkan ambiguitas yang mungkin terjadi ketika kata tersebut muncul dalam konteks positif. Misalnya, kata-kata seperti "tidak" dan "bukan" bisa merubah makna sebuah kalimat menjadi negatif, meskipun kata yang mengikuti adalah kata positif. Untuk mengatasi ini, transformasi kata ini dilakukan agar kalimat tetap memiliki makna yang sesuai dengan sentimen yang dimaksud. Rincian tentang model yang diusulkan, termasuk parameter dan konfigurasi yang digunakan, dapat ditemukan dalam Tabel 3.3. Tabel ini

memberikan pandangan menyeluruh tentang berbagai komponen dan pengaturan yang digunakan dalam pengembangan model, seperti arsitektur model, ukuran batch, jumlah lapisan, dan lainnya. Dengan merinci ini, pembaca dapat memiliki gambaran yang jelas tentang bagaimana model dikonfigurasi untuk tugas klasifikasi sentimen dan aspek pada penelitian ini.

Tabel. 3.3 Daftar *stopword*

Datar Stopword Normalization	
apakah	Bagaimanakah
akankah	Bisakah
ataukah	Bisanya
adapun	bagaimanapun
adakah	beginilah

Dalam proses analisis sentimen berbasis aspek pada penelitian ini, ada dua tahapan klasifikasi yang dilakukan: pertama, klasifikasi sentimen, dan kedua, klasifikasi aspek. Peneliti membagi dataset menjadi dua subset, yaitu set pelatihan (training set) dan set pengujian (testing set), dengan proporsi 80% data digunakan untuk melatih model dan 20% untuk menguji model. Dalam upaya mendapatkan model terbaik, penelitian ini melakukan perbandingan antara tiga arsitektur deep learning, yaitu CNN, TCN, dan GRU. Pemilihan arsitektur dilakukan dengan tujuan untuk memahami bagaimana setiap model berkinerja dalam tugas klasifikasi yang kompleks ini. Selain itu, penelitian ini juga melakukan pemilihan hyperparameter untuk mengoptimalkan performa model. Pemilihan hyperparameter adalah langkah kritis dalam membangun model yang memiliki performa baik. Dalam hal ini, peneliti menggunakan fungsi "early stopping" untuk mencegah overfitting. Overfitting terjadi ketika model yang dilatih terlalu memahami data pelatihan dan tidak mampu melakukan generalisasi pada data baru. Untuk mendapatkan hasil yang lebih baik, peneliti juga melakukan variasi pada hyperparameter. Tabel 3.4 menjelaskan skenario hyperparameter yang diuji dalam penelitian ini. Hal ini penting untuk menemukan kombinasi hyperparameter yang memberikan kinerja terbaik pada masing-masing model. Melalui langkah-langkah ini, penelitian ini bertujuan untuk mengembangkan model sentiment analysis berbasis aspek yang memiliki kemampuan mengklasifikasikan sentimen dan aspek dengan akurat. Dengan menggunakan pemilihan arsitektur, pemilihan hyperparameter, dan tindakan pencegahan overfitting, peneliti berusaha untuk memastikan

bahwa model yang dihasilkan dapat memberikan hasil yang konsisten dan generalisasi yang baik pada data baru.

Tabel 3.4 Besar hyperparameter

Klasifikasi Sentimen			Klasifikasi Aspek			
Model	CNN	GRU	TCN	CNN	GRU	TCN
Filter	128	128	-	128	128	-
Kernel	5	-	64	5	-	64
Hidden dims	100	100	100	100	100	100
Input length	193	193	193	193	193	193
Drop out	-	0.1	0.1	-	0.1	0.1
Batch size	16	16	16	64	16	16
epoch	3	3	10	3	3	10

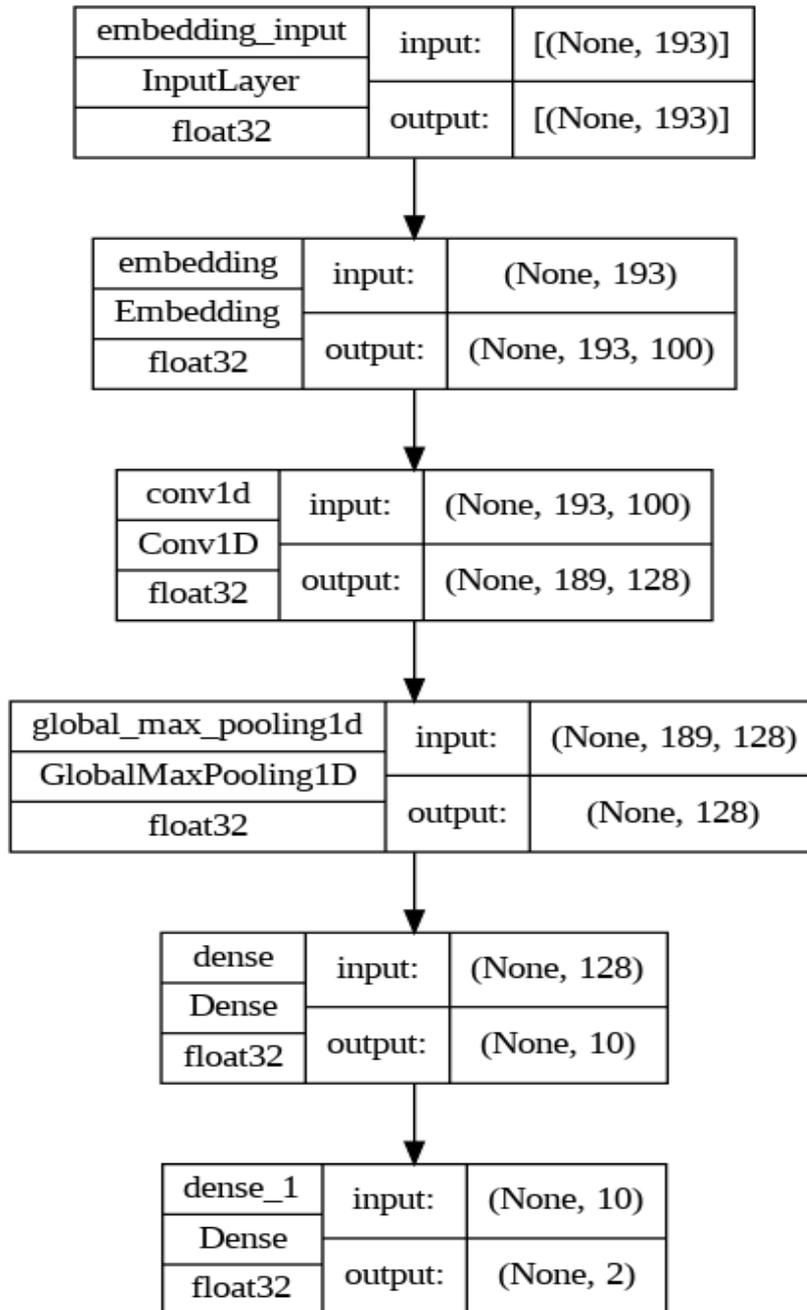
Arsitektur adalah representasi visual dari model yang digunakan, yang membantu kita untuk memahami struktur dan komponen utama model tersebut dengan lebih jelas. Dalam konteks klasifikasi sentimen menggunakan tiga model yaitu CNN, TCN, dan GRU, arsitektur tersebut menggambarkan bagaimana model bekerja dan bagaimana informasi mengalir melalui berbagai lapisan.

Dalam penelitian ini, arsitektur dari ketiga model tersebut dijelaskan sebagai berikut:

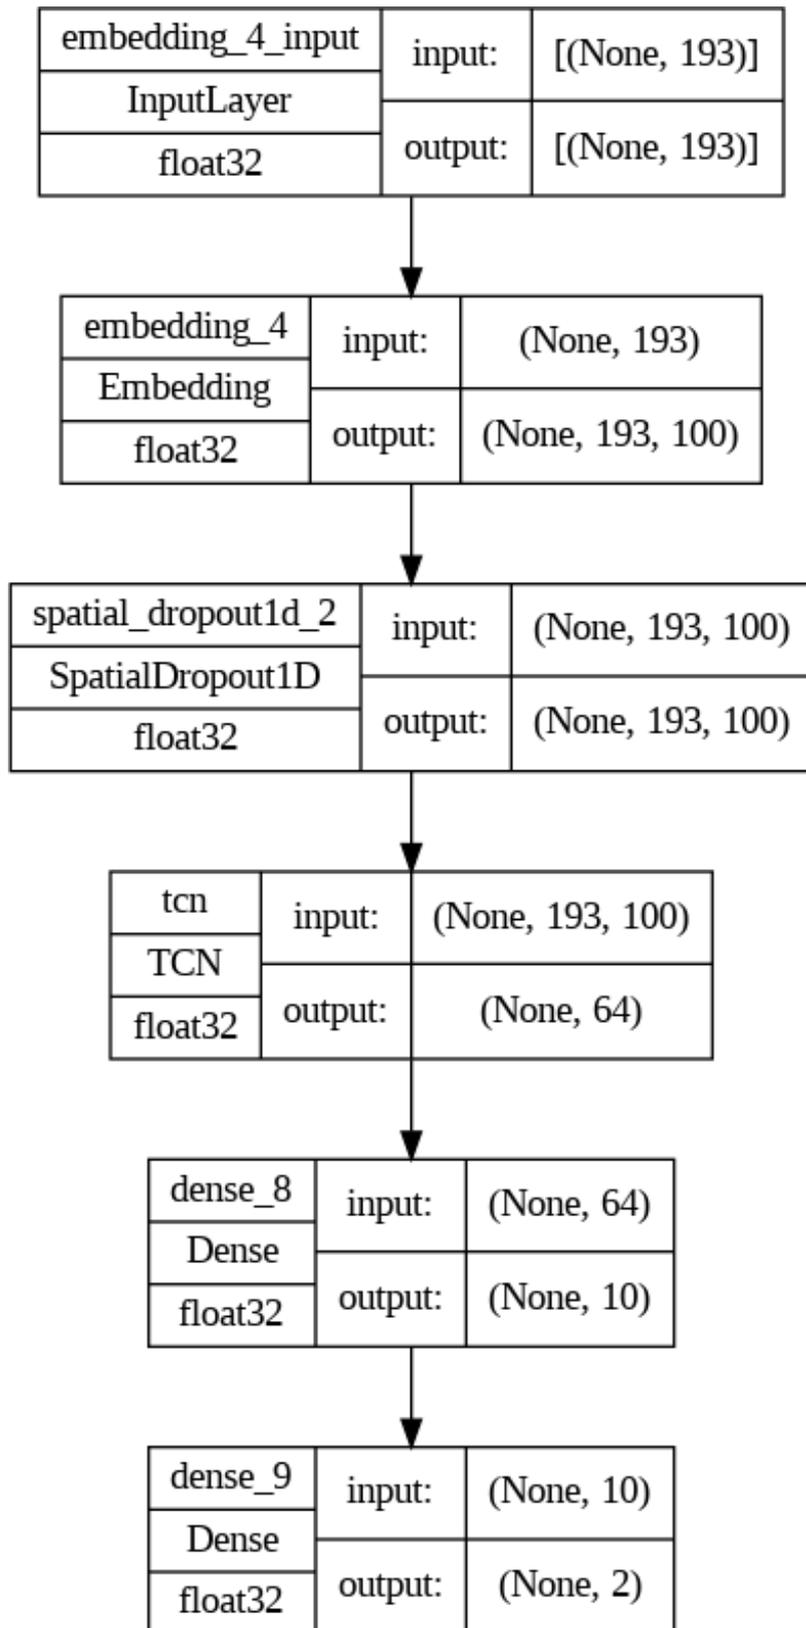
1. Arsitektur Model CNN (Gambar 3.3): Model Convolutional Neural Network (CNN) untuk klasifikasi sentimen digambarkan pada Gambar 3.3. Arsitektur ini mencakup lapisan konvolusi yang digunakan untuk mengenali fitur-fitur penting dalam teks ulasan, diikuti oleh lapisan pooling dan lapisan fully connected untuk menghasilkan output klasifikasi.
2. Arsitektur Model TCN (Gambar 3.4): Model Temporal Convolutional Network (TCN) digambarkan pada Gambar 3.4. TCN adalah jenis CNN yang khusus dirancang untuk data sekuensial, seperti teks. Arsitektur ini memiliki beberapa lapisan konvolusi temporal yang mampu memahami konteks sekuensial dari teks ulasan.
3. Arsitektur Model GRU (Gambar 3.5): Model Gated Recurrent Unit (GRU) untuk klasifikasi sentimen ditunjukkan pada Gambar 3.5. GRU adalah jenis jaringan rekuren yang membantu dalam memahami hubungan sekuensial dalam teks. Arsitektur ini memiliki lapisan GRU yang memungkinkan informasi bergerak ke depan melalui waktu.

4. Arsitektur Model CNN untuk Klasifikasi Aspek (Gambar 3.6): Pada tugas klasifikasi aspek, arsitektur Model CNN yang digunakan digambarkan pada Gambar 3.6. Arsitektur ini mirip dengan Model CNN untuk klasifikasi sentimen, tetapi diadaptasi untuk tugas klasifikasi aspek.
5. Arsitektur Model TCN untuk Klasifikasi Aspek (Gambar 3.7): Model TCN yang diadaptasi untuk tugas klasifikasi aspek ditunjukkan pada Gambar 3.7. Arsitektur ini memanfaatkan fitur-fitur TCN untuk memahami konteks sekuensial dari ulasan dan mengklasifikasikan aspek.
6. Arsitektur Model GRU untuk Klasifikasi Aspek (Gambar 3.8): Arsitektur Model GRU yang digunakan untuk tugas klasifikasi aspek digambarkan pada Gambar 3.8. Lapisan GRU dalam model ini membantu dalam memahami urutan kata dan memprediksi aspek yang relevan.

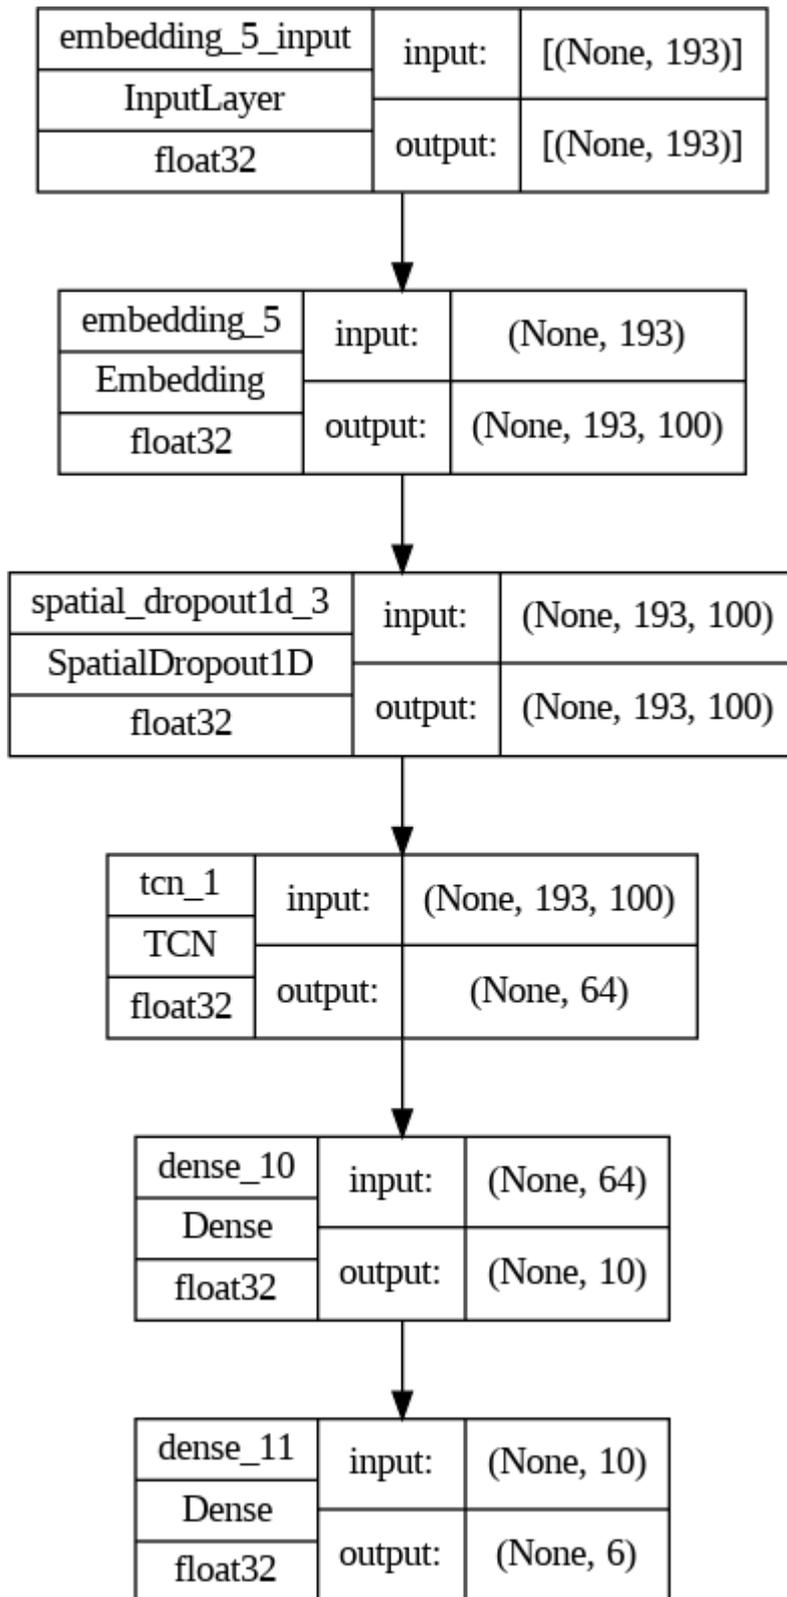
Dengan melihat arsitektur dari masing-masing model, peneliti dan pembaca dapat memahami bagaimana model-model tersebut dirancang dan bagaimana informasi mengalir melalui lapisan-lapisan untuk menghasilkan prediksi sentimen dan klasifikasi aspek.



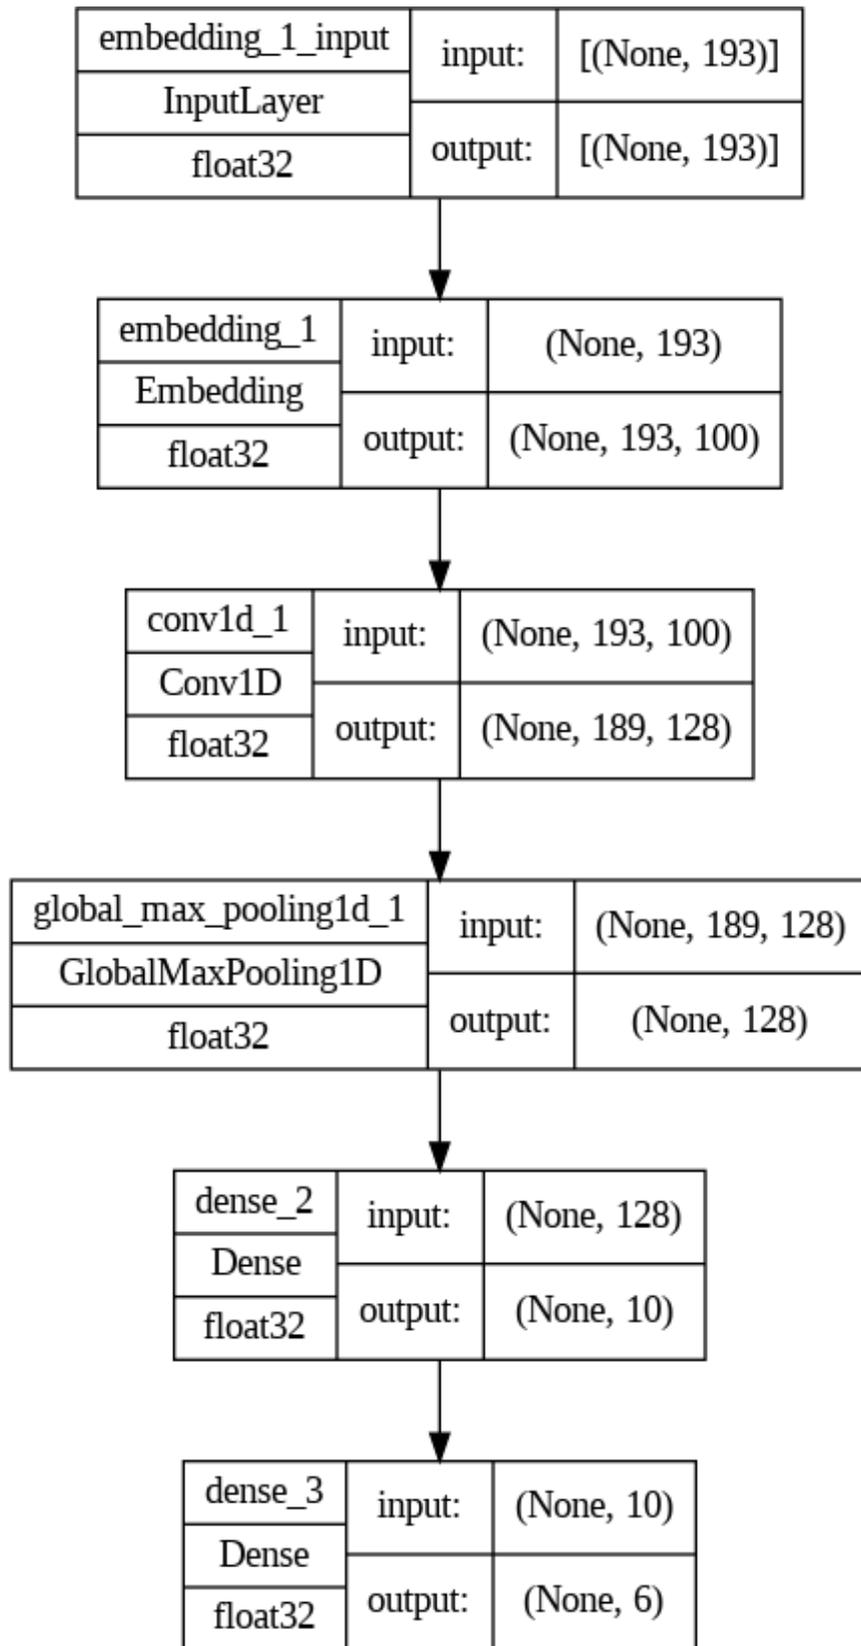
Gambar 3.3 Arsitektur klasifikasi sentimen model CNN



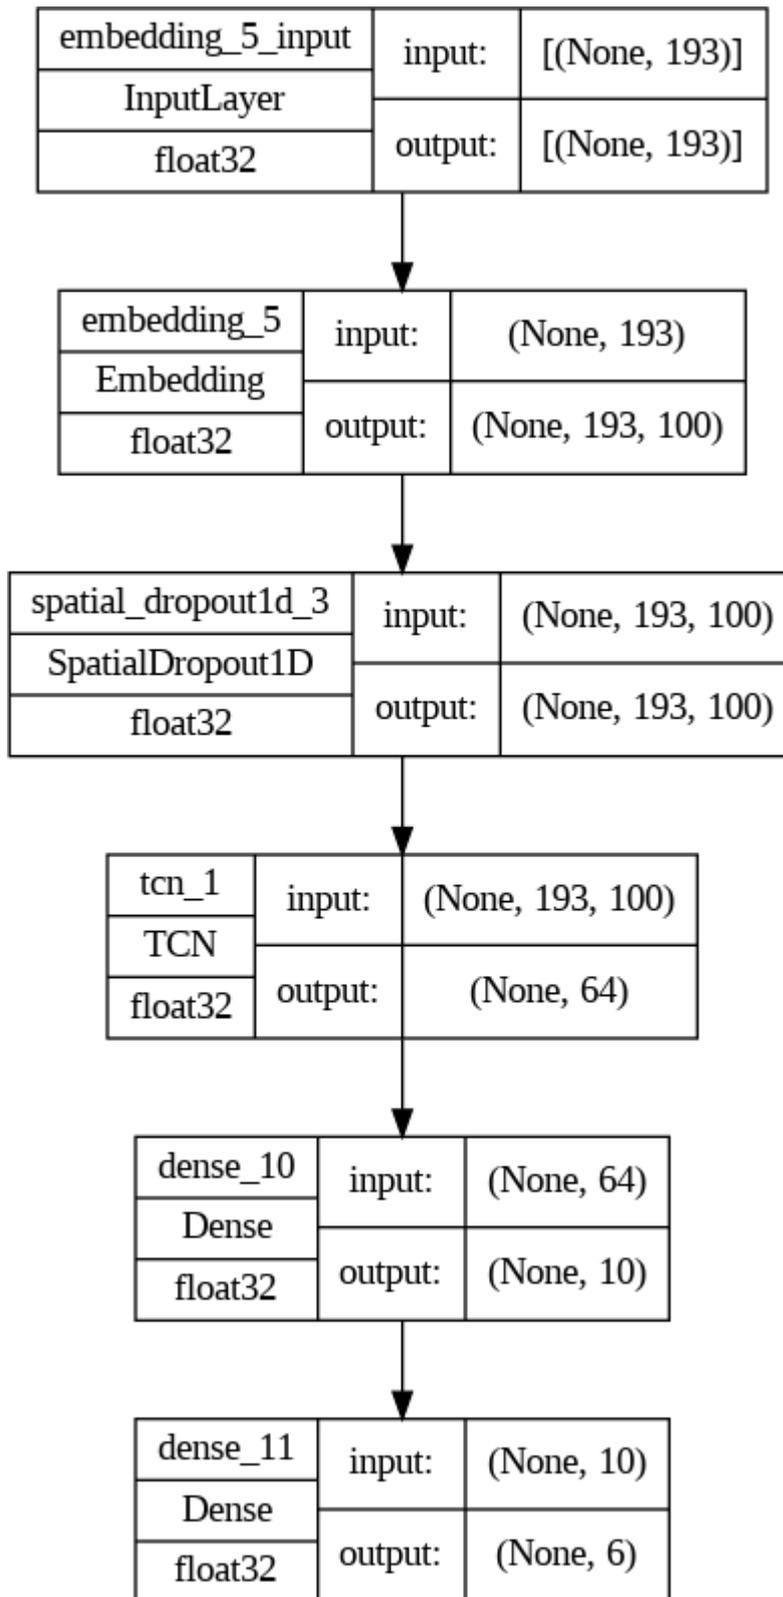
Gambar 3.4 Arsitektur klasifikasi sentimen model TCN



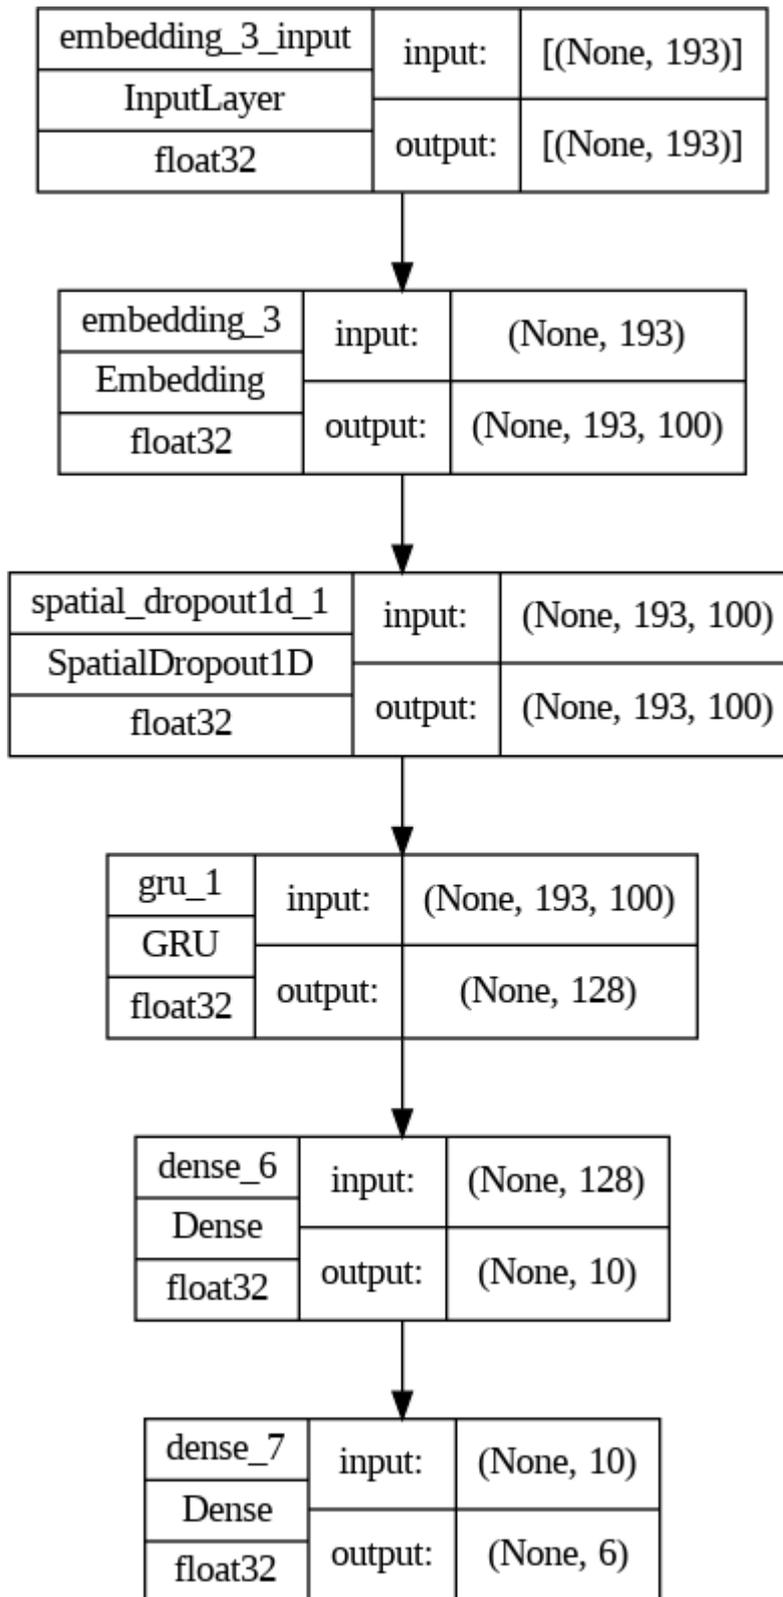
Gambar 3.5 Arsitektur klasifikasi sentimen model GRU



Gambar 3.6 Arsitektur klasifikasi aspek model CNN



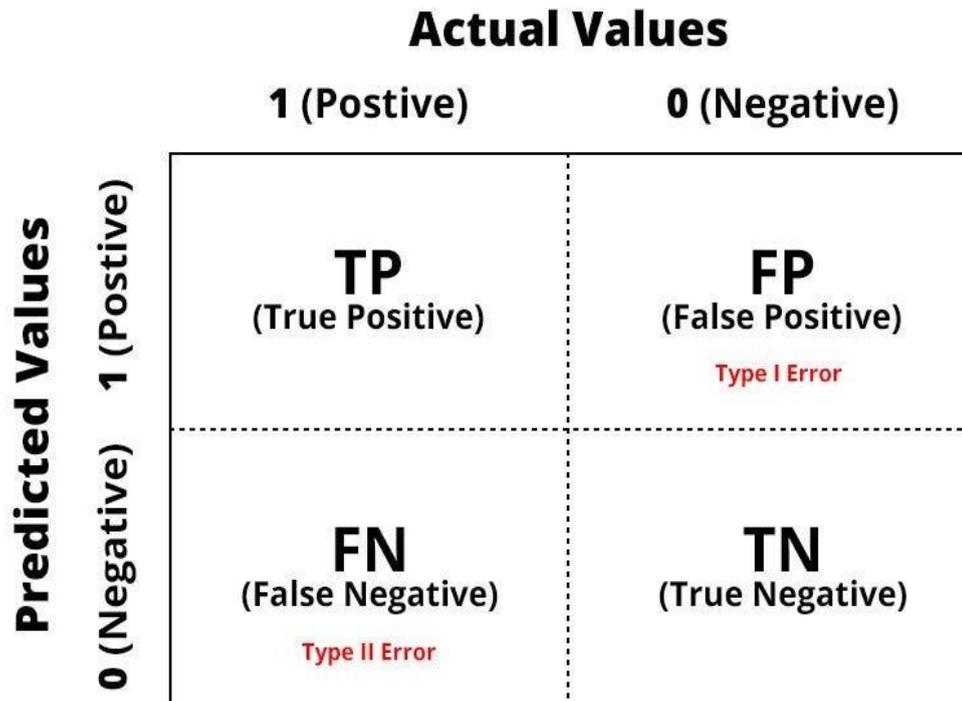
Gambar 3.7 Arsitektur klasifikasi aspek model TCN



Gambar 3.8 Arsitektur klasifikasi aspek model GRU

2.1.3 Evaluasi

Setelah mendapatkan hasil dari klasifikasi aspek dan sentimen, langkah selanjutnya adalah melakukan evaluasi untuk mengukur kinerja sistem yang telah dibangun. Pada penelitian ini, pendekatan deep learning digunakan dengan membandingkan metode CNN, TCN, dan GRU menggunakan fitur TF-IDF. Performa sistem diukur menggunakan metrik-metrik seperti akurasi, presisi, recall, dan F-Measure. Untuk melihat nilai-nilai ini, peneliti menggunakan confusion matrix. Confusion matrix adalah tabel yang berisi 4 kombinasi berbeda yang membantu kita dalam mengevaluasi sejauh mana sistem bekerja sesuai dengan yang diinginkan (Maragoudakis et al., 2016). Struktur dari confusion matrix dijelaskan dalam Gambar 3.9. Confusion matrix memberikan gambaran tentang seberapa baik model mengklasifikasikan data ke dalam kategori yang benar atau salah. Dengan menggunakan elemen-elemen dari confusion matrix, seperti true positive (TP), false positive (FP), true negative (TN), dan false negative (FN), kita dapat menghitung akurasi, presisi, recall, dan F-Measure. Metrik-metrik ini memberikan informasi yang lebih komprehensif tentang performa model dalam mengklasifikasikan data. Dengan melakukan evaluasi menggunakan confusion matrix dan metrik-metrik performa yang dihasilkan, peneliti dapat menilai seberapa baik model-model yang dibangun dalam melakukan tugas klasifikasi aspek dan sentimen pada aplikasi "pedulilindungi". Hal ini membantu untuk memahami apakah model-model tersebut mampu mengidentifikasi sentimen dan aspek dengan akurat, serta memberikan wawasan tentang area di mana model-model tersebut dapat ditingkatkan.



Gambar 3.9. Struktur Confusion Matrix

Pada Gambar 3.7, kita dapat melihat konsep dari true positif (TP), true negative (TN), false positif (FP), dan false negative (FN) dalam konteks confusion matrix (Maragoudakis et al., 2016).

1. True Positif (TP): Ini adalah jumlah data yang diprediksi dengan benar sebagai positif dan pada kenyataannya memang positif. Dalam konteks Gambar 3.7, ini menggambarkan data positif yang benar-benar diprediksi positif.
2. True Negative (TN): Ini adalah jumlah data yang diprediksi dengan benar sebagai negatif dan pada kenyataannya memang negatif. Dalam Gambar 3.7, ini menggambarkan data negatif yang benar-benar diprediksi negatif.
3. False Positif (FP): Ini adalah jumlah data yang diprediksi salah sebagai positif, padahal pada kenyataannya negatif. Dalam konteks gambar, ini menggambarkan data negatif yang salah diprediksi sebagai positif.
4. False Negative (FN): Ini adalah jumlah data yang diprediksi salah sebagai negatif, padahal pada kenyataannya positif. Dalam gambar, ini menggambarkan data positif yang salah diprediksi sebagai negatif.

Dengan memahami konsep ini, kita dapat mengukur kinerja model menggunakan berbagai metrik evaluasi. Beberapa persamaan yang digunakan dalam pengukuran performa evaluasi adalah:

1. Akurasi (Accuracy) = $(TP + TN) / (TP + TN + FP + FN)$
2. Presisi (Precision) = $TP / (TP + FP)$
3. Recall (Sensitivity atau True Positive Rate) = $TP / (TP + FN)$
4. Specificity (True Negative Rate) = $TN / (TN + FP)$
5. F-Measure (F1-Score) = $2 * (Presisi * Recall) / (Presisi + Recall)$

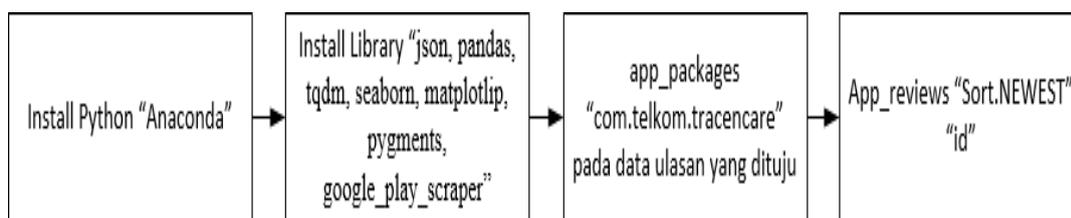
Metrik-metrik ini memberikan pemahaman yang lebih lengkap tentang seberapa baik model dalam mengklasifikasikan data dengan benar, terutama ketika ada ketidakseimbangan dalam distribusi kelas atau kategori. Dengan menerapkan metrik-metrik ini pada hasil evaluasi menggunakan confusion matrix, peneliti dapat mengukur dan membandingkan performa model dengan lebih baik.

BAB 4

Hasil dan Pembahasan

4.1 Dataset

Dataset yang digunakan dalam penelitian ini adalah data ulasan aplikasi "pedulilindungi" yang ditulis dalam bahasa Indonesia. Data ini diambil melalui proses web scraping dari situs Google Play Store. Proses web scraping dilakukan dengan menggunakan berbagai pustaka atau library yang tersedia dalam bahasa pemrograman Python, seperti "json", "pandas", "tqdm", "seaborn", "matplotlib", "pygments", dan "google_play_scraper". Dataset yang dihasilkan dari proses scraping kemudian diberi label berdasarkan rating yang diberikan oleh pengguna. Label tersebut terdiri dari dua polaritas, yaitu positif dan negatif. Skala rating (1-3) dianggap sebagai polaritas negatif, sementara skala rating (4-5) dianggap sebagai polaritas positif. Proses scraping data ulasan melibatkan beberapa langkah yang dijelaskan dalam Gambar 4.1. Langkah-langkah ini mencakup pengambilan data ulasan dari situs Google Play Store menggunakan library "google_play_scraper", penyimpanan data dalam format JSON, konversi JSON menjadi pandas DataFrame untuk analisis lebih lanjut, dan sebagainya. Dengan mengikuti langkah-langkah ini, peneliti berhasil mengumpulkan dan mempersiapkan dataset ulasan aplikasi "pedulilindungi" yang akan digunakan dalam analisis sentimen dan tugas klasifikasi aspek. Dataset ini memungkinkan peneliti untuk menganalisis dan memahami pandangan pengguna terhadap aplikasi ini serta melatih model dalam tugas-tugas analisis yang dilakukan dalam penelitian ini.



Gambar 4.1 Scraping data ulasan

Pengambilan data dilakukan dengan menggunakan bahasa pemrograman Python dan menginstall beberapa library yang telah disebutkan sebelumnya. Selanjutnya, packages tambahan diterapkan pada data ulasan yang akan diambil. Tahap terakhir, data ulasan terbaru berbahasa Indonesia diambil dengan menggunakan kode "id". Berikut adalah contoh script program untuk proses scraping:

```

#install library
import json
import pandas as pd
from tqdm import tqdm
import seaborn as sns
import matplotlib.pyplot as plt
from pygments import highlight
from pygments.lexers import JsonLexer
from pygments.formatters import TerminalFormatter

#scraping
from google_play_scraper import Sort, reviews, app
%matplotlib inline
%config InlineBackend.figure_format='retina'
sns.set(style='whitegrid', palette='muted', font_scale=1.2)

# alamat app pedulilindungi
app_packages = ['com.telkom.tracencare']

#info reviews berdasarkan Negara Indonesia Bahasa Indoseia
app_infos = []
for ap in tqdm(app_packages):
    info = app(ap, lang='id', country='id')
    del info['comments']
    app_infos.append(info)

#pengambilan data dalam bentuk “json”
def print_json(json_object):
    json_str = json.dumps(
        json_object,
        indent=2,
        sort_keys=True,

```

```

default=str
)
print(highlight(json_str, JsonLexer(), TerminalFormatter()))

#info app
print_json(app_infos[0])

# transformasi data ke csv.
app_infos_df = pd.DataFrame(app_infos)
app_infos_df.to_csv('apps.csv', index=None, header=True)

#pengambilan ulasan berdasarkan yang terbaru
app_reviews = []
for ap in tqdm(app_packages):
    for sort_order in [Sort.NEWEST]:
        rvs, _ = reviews(
            ap,
            lang='id',
            country='id',
            sort=sort_order,
            count= 100000,
        )
        for r in rvs:
            r['sortOrder'] = 'newest'
            r['appId'] = ap
            app_reviews.extend(rvs)

#menampilkan salah satu contoh data ulasan
print_json(app_reviews[0])

```

Gambar 4.2 Script program proses scraping data ulasan

```

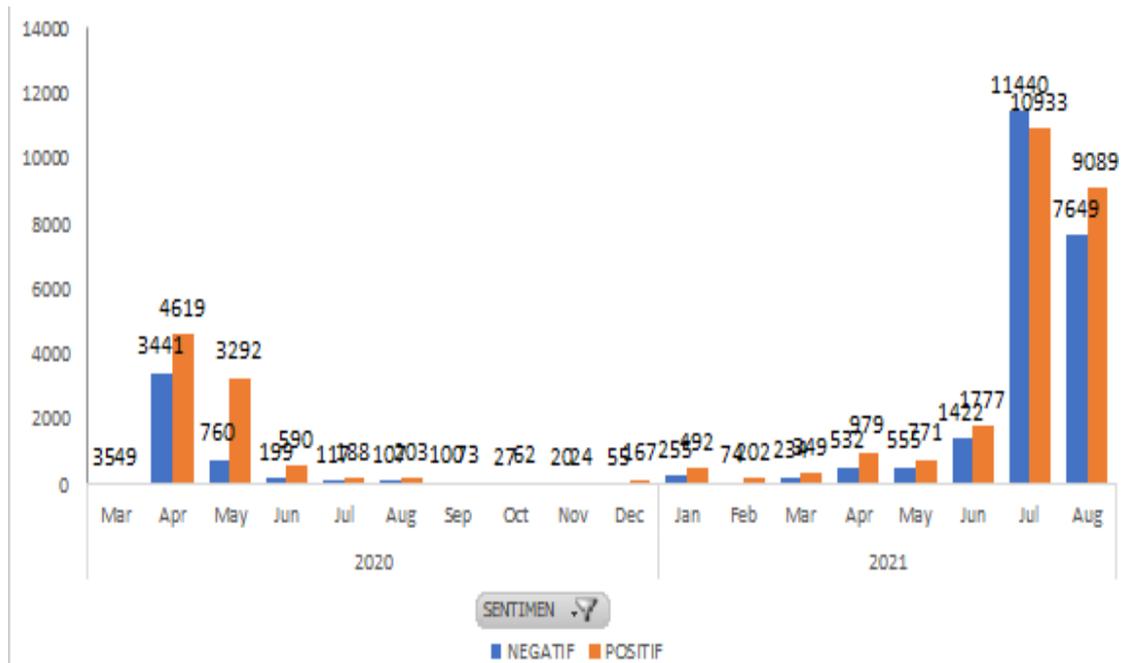
{
  "appId": "com.telkom.tracencare",
  "at": "2022-03-31 20:56:36",
  "content": "Bagus",
  "repliedAt": null,
  "replyContent": null,
  "reviewCreatedVersion": "4.0.9",
  "reviewId": "gp:A0qpTOEhO2RMzUBrbVFEBuD0FVeC54k3j1HLFTCyg9UGwdXs_1_huRgWPjGjBwII3revI-e9SR5F8SFy-Orp1MY",
  "score": 4,
  "sortOrder": "newest",
  "thumbsUpCount": 0,
  "userImage": "https://play-lh.googleusercontent.com/a/AATXAJzy_w0F3CU8Neoy6hurAbMke_too_je8IJ0--vk=mo",
  "userName": "Nurlelah Ella"
}

```

Gambar 4.3 Contoh ulasan user

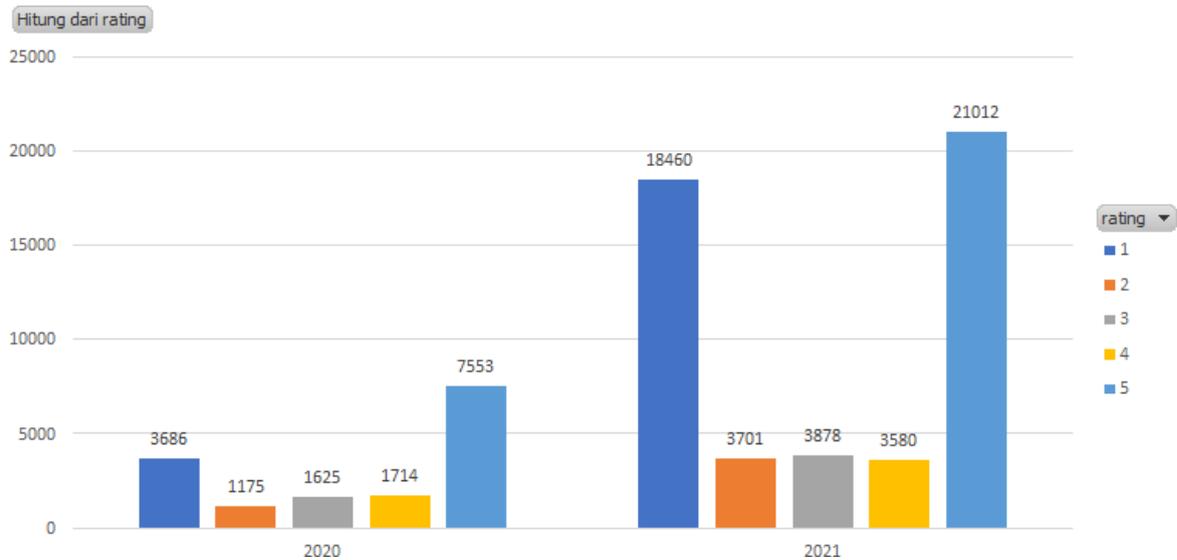
4.2 Descriptive Analysis

Analisis deskriptif dilakukan melalui proses web scraping dari situs Google Play Store, yang telah dilakukan sebelumnya, untuk memahami representasi persepsi pengguna terkait pelayanan yang diberikan oleh aplikasi "pedulilindungi". Gambar 4.4 menampilkan grafik sentimen dari tahun 2020 hingga 2021. Proses web scraping melibatkan pengambilan data dari ulasan dan penilaian pengguna pada platform Google Play Store. Data ini kemudian dianalisis untuk mendapatkan wawasan tentang bagaimana pengguna menggambarkan dan menilai aplikasi "pedulilindungi". Grafik sentimen yang dihasilkan dari analisis ini akan memvisualisasikan tren sentimen positif, negatif, atau netral dari ulasan-ulasan tersebut selama periode waktu yang ditentukan. Dengan memanfaatkan analisis deskriptif dan grafik sentimen ini, peneliti dapat memahami pandangan umum pengguna terhadap aplikasi "pedulilindungi" selama rentang waktu tertentu. Ini membantu dalam mengidentifikasi tren umum dan potensi masalah yang mungkin perlu diperbaiki atau ditingkatkan dalam pelayanan yang diberikan oleh aplikasi tersebut.



Gambar 4.4 Grafik Sentimen Per 2020-2021

Rentang pengambilan data yang Anda sebutkan adalah dari 31 Maret 2020 hingga 13 Agustus 2021. Selama tahun 2021, terutama pada bulan Juli dan Agustus, terjadi peningkatan signifikan dalam jumlah ulasan yang dibuat oleh pengguna untuk aplikasi PeduliLindungi. Peningkatan ini dapat dihubungkan dengan pelaksanaan program vaksinasi yang dilakukan pada tahun 2021. Pada bulan Juli 2021, tercatat sekitar 12.000 ulasan pengguna, yang menunjukkan adanya antusiasme dan partisipasi yang lebih tinggi dalam penggunaan aplikasi. Hal ini berkaitan erat dengan implementasi sertifikat vaksinasi sebagai persyaratan untuk proses validasi kesehatan atau penyimpanan password digital. Kewajiban dari pemerintah untuk menggunakan aplikasi PeduliLindungi sebagai bagian dari upaya penanggulangan pandemi turut mendorong peningkatan instalasi aplikasi dan berkontribusi pada peningkatan jumlah ulasan. Meskipun pada bulan Agustus 2021 terjadi sedikit penurunan dengan sekitar 10.000 ulasan, hal ini masih mengindikasikan tingkat partisipasi yang tinggi dari pengguna dalam memberikan ulasan terkait aplikasi tersebut. Faktor-faktor seperti program vaksinasi, kewajiban penggunaan aplikasi, serta kepatuhan terhadap peraturan pemerintah memiliki peran penting dalam peningkatan jumlah ulasan dan interaksi positif dengan aplikasi PeduliLindungi selama rentang waktu yang Anda sebutkan.



Gambar 45 Grafik Sebaran Rating

Peningkatan jumlah ulasan pada tahun 2021 dapat dihubungkan dengan penerapan kebijakan pemerintah yang mewajibkan penggunaan aplikasi PeduliLindungi. Kebijakan ini mungkin berkontribusi pada peningkatan jumlah pengguna yang mengunduh dan menginstal aplikasi tersebut. Dalam grafik yang Anda sebutkan, terdapat beberapa informasi yang bisa diambil:

Jumlah ulasan rating naik secara signifikan pada tahun 2021. Dalam kategori "Sangat Suka," terdapat 21.012 ulasan lebih banyak dibandingkan tahun sebelumnya. Ini menunjukkan bahwa banyak pengguna merasa puas dan senang dengan aplikasi PeduliLindungi. Rating pada ulasan tersebut memiliki kategori yang berkisar dari 1 hingga 5. Setiap kategori memiliki makna yang berbeda: 1 (Sangat Tidak Suka), 2 (Kurang Suka), 3 (Netral), 4 (Suka), dan 5 (Sangat Suka). Peningkatan yang signifikan pada kategori "Sangat Suka" dan "Sangat Tidak Suka" menunjukkan adanya perubahan persepsi yang kuat di antara pengguna. Penerapan kebijakan pemerintah yang mewajibkan penggunaan aplikasi PeduliLindungi tampaknya menjadi faktor yang mendorong peningkatan penggunaan dan ulasan positif. Kebijakan ini mungkin telah merangsang lebih banyak orang untuk mengunduh, menginstal, dan menggunakan aplikasi tersebut. Dengan peningkatan jumlah ulasan di kategori "Sangat Suka," dapat diasumsikan bahwa pengguna merasa puas dengan pengalaman menggunakan aplikasi PeduliLindungi. Penggunaan aplikasi ini mungkin memberikan manfaat yang signifikan, seperti memberikan informasi terkait pandemi, pelacakan kontak, atau mungkin memiliki antarmuka yang mudah digunakan.

4.3 Sentimen Multi Aspek

Dalam penelitian ini, telah dilakukan proses scraping yang menghasilkan sebanyak 66.385 data ulasan. Selanjutnya, penentuan polaritas sentimen dilakukan berdasarkan rating yang diberikan oleh pengguna. Jika dilihat dari Gambar 4.5, terlihat bahwa grafik sebaran rating untuk polaritas netral tidak begitu signifikan. Oleh karena itu, dalam rangka mempermudah analisis menggunakan metode mesin, keputusan diambil untuk menganggap polaritas netral sebagai sentimen negatif. Aspek-aspek dalam dataset ini dikategorikan berdasarkan topik yang sering muncul dalam ulasan. Dalam penelitian ini, aspek-aspek yang diidentifikasi meliputi aplikasi, antarmuka pengguna (user interface), pengalaman pengguna (user experience), kode OTP, proses pengunduhan sertifikat vaksin, dan akses layanan publik. Sentimen yang berkaitan dengan setiap aspek ditentukan dengan mencari kata kunci yang relevan, dan ini menghasilkan sekitar 23.183 data ulasan yang mencakup informasi mengenai aspek, sentimen, dan rating pengguna. Untuk melabeli sentimen berdasarkan aspek, proses pelabelan dilakukan berdasarkan rating yang diberikan oleh pengguna pada setiap ulasan. Contoh dataset dapat ditemukan pada Tabel 4.1.

Tabel 4.1 Contoh Dataset Ulasan

Ulasan	Rating	Aspek	Sentimen
Aplikasi sampah tidak terdeteksi lokasi kota hanya terdeteksi 1 wilayah payah bikin aplikasi asal banget developer sory uninstall aplikasi kasih bintang 1 aplikasi tidak membantu	1	Aplikasi	Negative
Sebagian fitur tidak berfungsi, masa mau login isi tanggal lahir tidak bisa gimana ini	2	User Interface	Negative
Vaksin pertama ada aplikasi muncul sertifikat vaksin2 tidak muncul bingung	2	User experience	Negative
Server nya lambat respon kode otp lelet mohon dikirim cepat otpnya	1	Kode OTP (One time password)	Negative
Membantu proses unduh sertifikat vaksin 1 n 2 cepat	5	Kartu Vaksin	Positive
Call center sulit hubung sertifikat vaksin	2	Akses	Negative

muncul lambat layanan		layanan	
-----------------------	--	---------	--

Dataset yang sukses dikumpulkan selanjutnya didistribusikan ke dalam kelas aspek maupun sentimen tujuannya untuk melihat sebaran data pada tiap jumlah kelasnya. Dimana pada distribusi jumlah kelas aspek maupun sentimen terdiri dari 9.217 dan 13.966 data positif dan data negative. Tabel 4.2 adalah distribusi kelas aspek maupun sentimen pada dataset.

Tabel 4.2 distribusi kelas aspek

Aspek	Positive	Negative	Total
Aplikasi	2534	3180	5714
User Interface	1171	1901	3072
User Experience	1006	2235	3241
Kode OTP	1938	332	2270
Unduh Sertifikat Vaksin	2138	5348	7486
Bukti Akses Layanan Publik	430	970	1400
	9217	13.966	23.183

4.4 Preprocessing Data

Dataset yang diperoleh dari proses scraping belum dapat digunakan karena data teks tersebut belum terstruktur sehingga perlu untuk di preprocessing agar data terstruktur untuk mengurangi beberapa permasalahan yang bisa mengganggu saat pemrosesan data, menyaring term yang tidak memiliki arti melalui serangkaian tahapan yang telah disebutkan sebelumnya dengan menggunakan tools berupa python. Guna memudahkan proses klasifikasi tahapan text preprocessing yang digunakan yaitu:

1. Case Folding

Proses casefolding diperlukan untuk mengkonversi semua teks yang terdapat pada dokumen guna menyeragamkan semua huruf menjadi huruf kecil dengan menggunakan fungsi “lower”. Gambar 4.6 script program proses case folding.

```
def casefolding(commentx):
    comment = commentx.lower()
    comment = comment.strip(" ")
    comment = re.sub(r'[?|$|.|!|^_:"') (-+,]', '', comment)
    return comment
```

Gambar 4.6 Script program proses case folding.

2. Tokenize

Tahap ini dilakukan untuk mengubah kalimat menjadi bentuk word by word dengan pemisah koma. Gambar 4.7 potongan script program prose tokenization.

```
def tokenisasi(comment):
    comments = str(comment)
    nstr = comments.split(' ')
    dat= []
    a = -1
    for hu in nstr:
        a = a + 1
        if hu == '':
            dat.append(a)
    p = 0
    b = 0
    for q in dat:
        b = q - p
        del nstr[b]
        p = p + 1
    return nstr
```

Gambar 4.7 Script program prose tokenization.

3. Normalization

Normalization Indonesia slang dilakukan untuk mengkonversi kata tidak baku menjadi kata baku guna menyeragamkan kata yang bermakna ganda. Gambar 4.8 potongan script program proses normalization.

```
def normalisasi(cetences):
    new_cetences = []
    if(len(cetences)>0):
        for word in cetences.split(' '):
            new_word = word
            for i in range(len(dict)):
                if(new_word==dict.loc[i][0]):
                    new_word=dict.loc[i][1]
                    break
            new_cetences.append(new_word)
    return ' '.join(new_cetences)
```

Gambar 4.8 script program proses normalize

4. *Remove Stop-word*

Remove stop-word adalah tahap pemilihan kata yang memiliki frekuensi kata yang sering muncul namun tidak memberikan makna. Proses remove stop-word dilakukan guna mengurangi ukuran dataset tujuannya untuk mengurangi waktu pada saat proses pelatihan karena jumlah data yang digunakan akan kurang (Salwa Kamila, H et al., 2021). Gambar. 4.9.

```
def stopwords_removal(comments):
    stop_words = set(stopwords.words('indonesian', 'english'))
    word_tokens = word_tokenize(comments)
    filtered_sentence = [w for w in word_tokens if not w.lower(
) in stop_words]
    filtered_sentence = []
    for w in word_tokens:
        if w not in stop_words:
            filtered_sentence.append(w)
    return filtered_sentence
```

Gambar 4.9 Script program proses *stop-word*

5. *Stemming*

Tahapan stemming dilakukan guna memperkecil jumlah indeks menghilangkan imbuhan tanpa harus menghilangkan makna. Gambar 4.10 script program proses stemming.

```

def stemming(comments):
    factory = StemmerFactory()
    stemmer = factory.create_stemmer()
    do = []
    for w in comments:
        dt = stemmer.stem(w)
        do.append(dt)
    d_clean= " ".join(do)
    return d_clean
dict = pd.read_csv('kamus.csv', header=None)
def normalisasi(cetences):
    new_cetences = []
    if(len(cetences)>0):
        for word in cetences.split(' '):
            new_word = word
            for i in range(len(dict)):
                if(new_word==dict.loc[i][0]):
                    new_word=dict.loc[i][1]
                    break
            new_cetences.append(new_word)
    return ' '.join(new_cetences)

```

Gambar 4.10 script program proses stemming

Setelah melewati proses preprocessing pada dataset ulasan yang digunakan lalu disimpan ke dalam format file csv sebagai dataset yang bersih sehingga bisa untuk dilakukan pada tahap selanjutnya. Tabel 4.3 Hasil dataset yang sudah dibersihkan (preprocessing).

Tabel 4.3 Contoh Data Setelah Preprocessing

Teks Sebelum	Teks Setelah
Aplikasi sampah tidak terdeteksi lokasi kota hanya terdeteksi 1 wilayah payah bikin aplikasi asal banget developer sory uninstall aplikasi kasih bintang 1 aplikasi tidak membantu	aplikasi sampah tidak deteksi lokasi kota hanya deteksi 1 wilayah payah bikin aplikasi asal banget developer sory uninstall aplikasi kasih bintang 1 aplikasi tidak bantu
Sebagian fitur tidak berfungsi mau login isi tanggal lahir tidak bisa, gimana ini	sebagian fitur tidak fungsi mau login isi tanggal lahir tidak bisa gimana ini
Vaksin pertama ada aplikasi muncul sertifikat vaksin2 tidak muncul bingung	vaksin pertama ada aplikasi muncul sertifikat vaksin2 tidak muncul bingung
Servernya lambat respon kode otp lelet mohon dikirim cepat otpnya	server lambat respon kode otp lelet mohon kirim otp
Membantu proses unduh sertifikat vaksin 1 n 2 cepat	bantu proses unduh sertifikat vaksin 1 n 2 cepat

Call center sulit dihubungi sertifikat vaksin muncul lambat layanan	Call center sulit hubung sertifikat vaksin muncul lambat layan
---	--

4.5 Pembentukan Model ABSA

Teknik analisis sentimen berbasis aspek (ABSA) dilakukan dengan berbagai pendekatan. Dalam penelitian ini, ABSA dilakukan dengan memanfaatkan perangkat lunak berbasis cloud yang gratis dan dapat diakses melalui peramban seperti Mozilla Firefox dan Google Chrome. Ini memungkinkan dataset ABSA diunggah ke dalam penyimpanan cloud untuk kemudian dipanggil dari lingkungan kerja kolaboratif (Colab). Gambar 4.11 menunjukkan skrip program yang menjelaskan proses koneksi antara Colab dan penyimpanan cloud. Proses ABSA dilakukan dengan membandingkan pendekatan deep learning dan memanfaatkan berbagai pustaka sumber terbuka dalam bahasa pemrograman Python. Misalnya, "numpy" digunakan untuk perhitungan ilmiah seperti matriks dan aljabar. "Pandas" digunakan untuk memproses data dan membaca berbagai format file seperti txt, xml, csv, dan lain-lain. "Seaborn" digunakan untuk visualisasi grafik dan statistik. "Sklearn" digunakan untuk pelatihan data dan tambahan "keras-tnn" digunakan untuk melatih arsitektur TCN. Sebelum dilakukan pembagian dataset, data dipecah menjadi token dan kemudian menerapkan konsep TF-IDF (Term Frequency-Inverse Document Frequency). Gambar 4.12 mengilustrasikan skrip program yang menjelaskan proses TF-IDF. Tahap konversi teks ke dalam urutan integer indeks kata atau vektor yang merujuk pada kamus token dilakukan menggunakan "tokenizer" dan "count_vector". Gambar 4.13 menunjukkan skrip program untuk proses ini. Setelah proses tokenisasi selesai, langkah selanjutnya adalah one-hot encoding dengan bantuan "Sklearn". Ini mengubah data kategorikal menjadi bentuk data biner. Gambar 4.14 menggambarkan skrip program one-hot encoding. Dikarenakan distribusi data yang tidak seimbang, peneliti menerapkan metode undersampling. Metode ini dilakukan dengan mengambil sampel baris pada setiap aspek berdasarkan distribusi aspek yang paling sedikit, dengan tujuan untuk mencegah overfitting. Gambar 4.15 menunjukkan skrip program untuk proses undersampling data sentimen dan aspek. Pada akhir model, peneliti menggunakan categorical_crossentropy sebagai metrik untuk menghitung probabilitas prediksi dan probabilitas aktual. Untuk optimasi, metode adam dipilih karena telah terbukti memberikan hasil yang baik dan telah digunakan dalam banyak penelitian terdahulu. Threshold dicapai dengan menerapkan callback khusus dan fungsi early stopping untuk memonitor kerugian validasi dalam proses pelatihan.

```
from google.colab import drive
drive.mount('/content/drive', force_remount = True)
```

Gambar 4.11 script program proses koneksi colab ke drive

```
count_vector = TfidfVectorizer(
    ngram_range = (1, 2)
)
count_vector.fit(data['review'])
```

Gambar 4.12 script program proses *tf-idf*

```

tokenizer = Tokenizer(num_words = variance_word, oov_token = "<OOV>")

tokenizer.fit_on_texts(data['review'])

sample_text = data['review'].sample(1).values[0]
sample_text

tokenized_sentence = tokenizer.texts_to_sequences(sample_text)
print(tokenized_sentence)

print(pad_sequences(tokenized_sentence))

```

Gambar 4.13 script program proses pemecahan kata menjadi nilai vector

```

X_train_vec      = feature_vec
y_train_sentiment = target_sentiment
y_train_aspect   = target_aspect

```

Gambar 4.14 script program *one-hot encoding*

```

data = data.groupby('aspect', group_keys=False).apply(lambda df:
df.sample(1400)).reset_index().drop('index', axis = 1

```

Gambar 4.15 script program downsampling data sentimen dan aspek

Dalam penelitian ini, kami menerapkan teknik undersampling untuk menangani masalah ketidakseimbangan kelas pada dataset ulasan pedulilindungi. Teknik ini bertujuan untuk mengurangi jumlah sampel dari kelas mayoritas sehingga sejajar dengan kelas minoritas, yang dapat meningkatkan kinerja model dalam mengenali pola dari kedua kelas.

Setelah proses undersampling dilakukan, kami mengamati perbedaan antara data sebelum dan setelah penerapan teknik ini, seperti yang terlihat dalam Tabel 4.4. Selanjutnya, kami melakukan transformasi kata menjadi nilai vektor dan membagi data menjadi dua subset, yaitu set pelatihan (train set) dan set pengujian (test set). Data pelatihan digunakan untuk melatih model dalam memahami pola-pola dalam dataset dan untuk membuat prediksi terhadap data baru. Sementara itu, data pengujian digunakan untuk menguji sejauh mana model yang telah dilatih dapat menggeneralisasi pada data yang belum pernah dilihat sebelumnya.

Untuk pembagian dataset menjadi data pelatihan dan data pengujian, kami menerapkan pendekatan split 80/20. Artinya, 80% dari data digunakan sebagai data pelatihan, sementara 20% sisanya digunakan sebagai data pengujian. Langkah ini

dimaksudkan untuk memastikan bahwa model memiliki cukup data untuk belajar namun juga diuji pada data yang independen. Setelah pembagian dataset dilakukan, langkah selanjutnya adalah tahap pengenalan pola menggunakan metode deep learning. Kami membandingkan tingkat akurasi dari tiga pendekatan deep learning yang berbeda, yaitu Convolutional Neural Network (CNN), Temporal Convolutional Network (TCN), dan Gated Recurrent Unit (GRU). Gambar 4.16 script program proses data split menggunakan *train_test_split* dari library *sklearn*. Proses pembagian data menjadi data pelatihan dan data pengujian dilakukan menggunakan fungsi `train_test_split` yang disediakan oleh pustaka Scikit-learn (*sklearn*). Fungsi ini memastikan bahwa pemisahan data dilakukan secara acak, sehingga mewakili distribusi data secara merata dalam kedua subset.

Tabel. 4.4 Hasil downsampling

Undersampling			
Sebelum		Sesudah	
unduh kartu vaccine	7486	akses layanan	1400
aplikasi	5714	aplikasi	1400
user experience	3225	kode OTP	1400
user interface	3072	unduh kartu vaccine	1400
kode OTP	2270	user experience	1400
akses layanan	1400	user interface	1400
Name: aspect, dtype: int64		Name: aspect, dtype: int64	

```
X_train_vec, X_test_vec, y_train, y_test = train_test_split(
    feature_vec,
    target,
    test_size = 0.2,
    random_state = 1
)
```

Gambar 4.16 script program proses data split

Data yang digunakan pada proses klasifikasi dalam penelitian ini adalah data teks yang sudah dibersihkan dan label aspek maupun sentiment yang sudah di proses sebelumnya terdapat pada tabel 4.2 dari setiap dokumen. Setelah data siap untuk digunakan selanjutnya adalah menerapkan beberapa model deep learning yang diaplikasikan guna memperoleh model terbaik dan skala *tuning hyperparameter* yang digunakan pada penelitian yang sudah diimplementasikan pada tabel 3.4. representasi dari rangkaian model yang dibangun pada penelitian.

1. CNN

Penelitian ini membangun CNN model terdiri dari beberapa *layer*, *layer* pertama menyimpan kata dalam sebuah *low-dimensional vector*, *layer* kedua menjalankan *convolutions* menggunakan *multiple filter size*, selanjutnya *max-pool* hasil dari *layer convolutional* ke dalam *long feature vector*, menambahkan *fully connected dropout regularization*, dan mengklasifikasi hasil menggunakan *ReLU layer* di akhir jaringan peneliti menambahkan *softmax* untuk klasifikasi aspek Gambar 4.17 script program model CNN

```
def build_model_cnn(n_classes, n_filter = 128, n_kernel =
5):

    model = Sequential()

    model.add(Embedding(input_dim = variance_word,
output_dim = 100, input_length = 193))
    model.add(Conv1D(n_filter, n_kernel, activation =
"relu"))
    model.add(GlobalMaxPooling1D())
    model.add(Dense(10, activation = "relu"))
    model.add(Dense(n_classes, activation = "softmax"))

    model.compile(
        optimizer="adam",
        loss = "categorical_crossentropy",
        metrics = ['acc']
    )

    return model
```

Gambar 4.17 script program CNN model.

2. TCN

Model TCN menggunakan 1D *fully-convolutional network* pada teks klasifikasi yang memiliki karakteristik konvolusi dalam arsitektur bersifat kausal dengan panjang input dan output yang sama di mana urutan dan keluaran berdasarkan distribusi. Selanjutnya causal convolutions di mana tiap *hidden layer* mempunyai panjang yang sama dengan *input layer* dan panjang *padding 0* (*kernel size besar 64* diset untuk mempercepat temporal konvolusi apabila kernel size nya berukuran

kecil maka TCN dalam melakukan scanning akan lebih lama. Untuk faktor dilated peneliti ini menggunakan [4, 8] karena bidang reseptif yang lebih besar (yaitu tidak ada kehilangan cakupan) Efisien secara komputasi Gambar 4.18 script program TCN model.

```
def build_model_tcn(n_class: int = 2):
    model = Sequential()
    model.add(Embedding(input_dim = variance_word, output_dim
= 100, input_length = 193))
    model.add(SpatialDropout1D(0.1))
    model.add(TCN(kernel_size=64, dilations=[4, 8]))
    model.add(Dense(10, activation = "relu"))
    model.add(Dense(n_class, activation = "softmax"))

    model.compile(
        optimizer = "adam",
        loss = "categorical_crossentropy",
        metrics = ['acc']
    )
    return model
```

Gambar 4.18 script program TCN model.

3. GRU

Pada model GRU hanya menggunakan beberapa lapisan model ini tidak menggunakan Conv 1D, dan Max pool 1D dan menambahkan GRU sebelum dense layer. Gambar 4.19 script program GRU model.

```
def build_model_gru(n_class: int = 2):
    model = Sequential()
    model.add(Embedding(input_dim = variance_word,
output_dim = 100, input_length = 193))
    model.add(SpatialDropout1D(0.1))
    model.add(GRU(128, return_sequences = False))
    model.add(Dense(10, activation = "relu"))
    model.add(Dense(n_class, activation = "softmax"))
    model.compile(
        optimizer = "adam",
        loss = "categorical_crossentropy",
        metrics = ['acc']
    )
    return model
return model
```

Gambar 4.19 script program GRU model.

Setelah proses hasil pelatihan model, selanjutnya yaitu mengevaluasi sebuah model yang sudah diimplementasikan pada formula (7), (8), dan (9) sebelumnya untuk melihat nilai akurasi dari setiap model. Agar dapat memperoleh nilai tersebut diperlukan *confusion matrix* guna mengetahui error pada performance kerja dari algoritma yang digunakan. Peneliti ini menggunakan tiga arsitektur CNN, TCN, dan GRU.

4.6 Pengujian dan Evaluasi

Untuk mendapatkan hasil yang baik dari 3 model yang digunakan, diperlukan pemilihan hyperparameter yang sesuai. Selanjutnya membandingkan hasil dari ketiga model yang digunakan yaitu CNN, TCN, dan GRU. Analisa pengkajian hasil dari ketiga model tersebut pada penyelesaian tugas akhir ini telah disiapkan beberapa model model hyperparameter seperti yang sudah dijelaskan di tabel 3.4 di atas dari masing-masing model.

1.6.1. Sentimen Klasifikasi

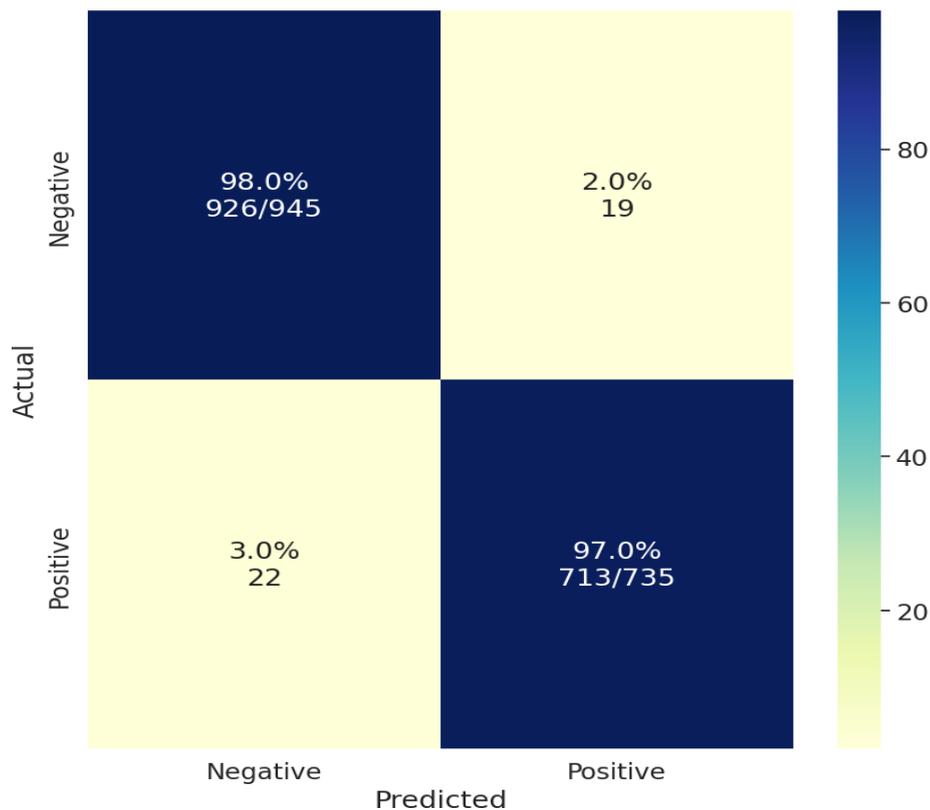
Pembangunan model dalam tugas klasifikasi sentimen melibatkan tiga model deep learning dan proses penyesuaian hyperparameter. Dalam tugas ini, data dari semua aspek digunakan untuk melakukan analisis sentimen. Hasil dari analisis klasifikasi sentimen ini tercatat dalam Tabel 4.5. Dari masing-masing model, terlihat bahwa nilai akurasi terbaik yang dihasilkan tidak memiliki perbedaan yang signifikan. Model CNN mencatat akurasi tertinggi, yakni sebesar 0.98, mengungguli dua model lainnya. Konfigurasi arsitektur CNN yang menghasilkan akurasi tertinggi terdiri dari 128 filter, 5 kernel, 100 hidden dimensions, 193 panjang input, dan ukuran batch 16. Selama proses pelatihan, model ini menggunakan penghentian awal epoch untuk menentukan kapan jumlah iterasi pelatihan harus berhenti saat model telah mencapai performa yang optimal. Hasil ini menunjukkan bahwa model CNN dengan konfigurasi tertentu mampu memberikan hasil akurasi tertinggi dalam klasifikasi sentimen dalam penelitian ini. Dalam pengembangan model, perbandingan hasil antara model-model ini dapat membantu memahami performa relatif dari setiap model dan konfigurasi hyperparameter yang digunakan.

Tabel 4.5 Hasil Evaluasi pada Klasifikasi Sentimen

Model	Precision	Recall	F1 Score	Accuracy
CNN	0.98	0.97	0.98	0.98
GRU	0.96	0.96	0.96	0.96
TCN	0.93	0.93	0.93	0.93

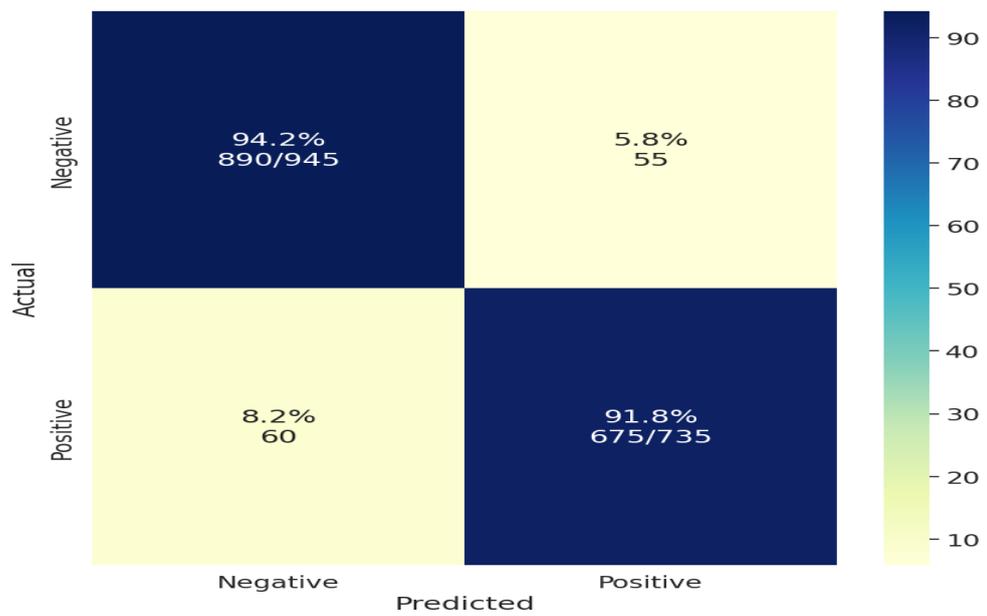
Setelah proses pelatihan dilakukan pada data uji, kita dapat memantau validasi loss untuk melihat seberapa baik model dalam memprediksi dan mengukur tingkat kesalahan. Model yang telah dilatih selanjutnya dievaluasi menggunakan confusion matrix. Dalam klasifikasi sentimen, akurasi tertinggi ditemukan pada model CNN dengan loss terendah sebesar 0.0921. Sementara itu, model TCN memiliki loss sebesar 0.1409 dan model GRU memiliki loss sebesar 0.1042. Penting untuk menggunakan confusion matrix dalam melihat performa model yang telah dibangun. Confusion matrix mampu memberikan wawasan tentang sejauh mana model mampu mengklasifikasikan data dengan benar dan menilai adanya jenis kesalahan yang terjadi. Detail dari confusion matrix dapat ditemukan dalam Gambar 4.19 untuk model CNN, Gambar 4.20 untuk model TCN, dan Gambar 4.21 untuk model GRU. Dengan memeriksa validasi loss dan hasil confusion matrix, Anda akan memiliki pemahaman yang lebih komprehensif tentang kinerja relatif dari model-model tersebut dalam konteks klasifikasi sentimen dan aspek pada aplikasi "pedulilindungi".

Confusion Matrix of Validation Data on CNN



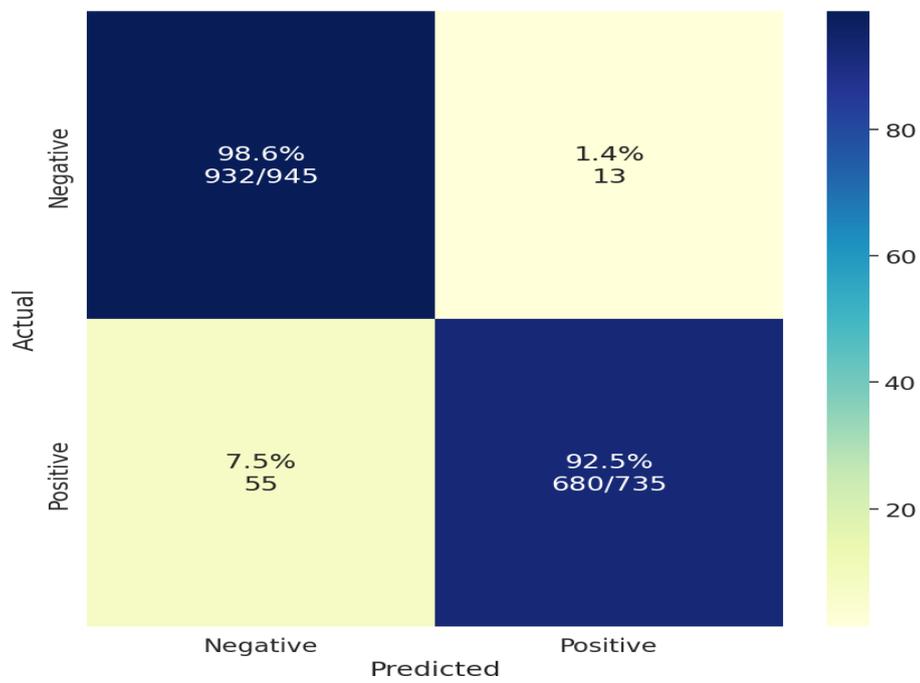
Gambar 4.20 Confusion Matrix CNN

Confusion Matrix of Validation Data on TCN



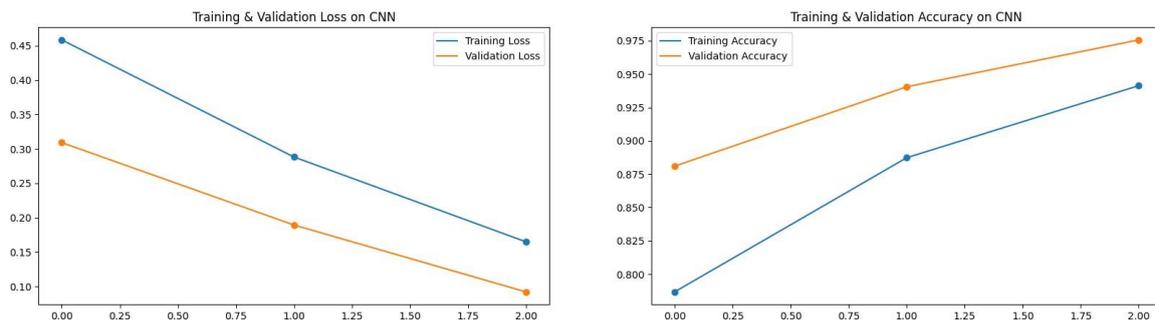
Gambar 4.21 Confusion Matrix TCN

Confusion Matrix of Validation Data on GRU



Gambar 4.22 Confusion Matrix GRU

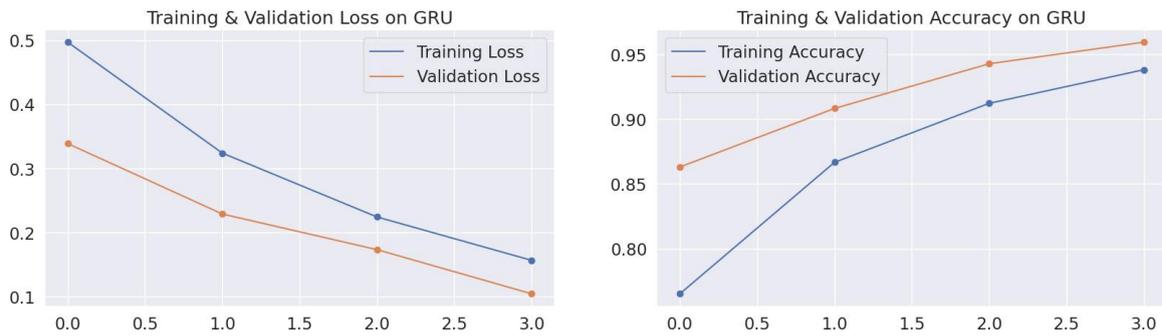
Untuk mencapai hasil yang optimal dari ketiga model yang digunakan (CNN, TCN, dan GRU), penting untuk melakukan pemilihan hyperparameter yang sesuai. Selanjutnya, perbandingan hasil dari ketiga model tersebut merupakan langkah penting dalam penelitian ini. Analisis hasil dari ketiga model ini melibatkan beberapa model hyperparameter, seperti yang telah dijelaskan dalam Tabel 3.4 di atas untuk masing-masing model. Dalam tahap ini, pemilihan hyperparameter yang tepat memiliki peran krusial dalam membentuk kinerja dan kemampuan generalisasi dari model. Melalui perbandingan antara model-model yang berbeda, Anda dapat mengidentifikasi konfigurasi hyperparameter yang memberikan hasil terbaik dalam hal akurasi, loss, atau metrik evaluasi lain yang relevan dengan tugas klasifikasi sentimen dan aspek. Dengan mempertimbangkan tabel hyperparameter dan hasil evaluasi, Anda akan dapat merumuskan kesimpulan tentang model mana yang memberikan hasil terbaik dalam konteks penelitian ini. Ini akan membantu memberikan wawasan yang kuat tentang kinerja dan efektivitas dari model CNN, TCN, dan GRU dalam tugas klasifikasi sentimen dan aspek dalam aplikasi "pedulilindungi".



Gambar 4.23 Grafik Loss & Accuracy Sentiment Model CNN



Gambar 4.24 Grafik Loss & Accuracy Sentiment Model TCN



Gambar 4.25 Grafik Loss & Accuracy Sentiment Model GRU

1.6.2. Aspek Klasifikasi

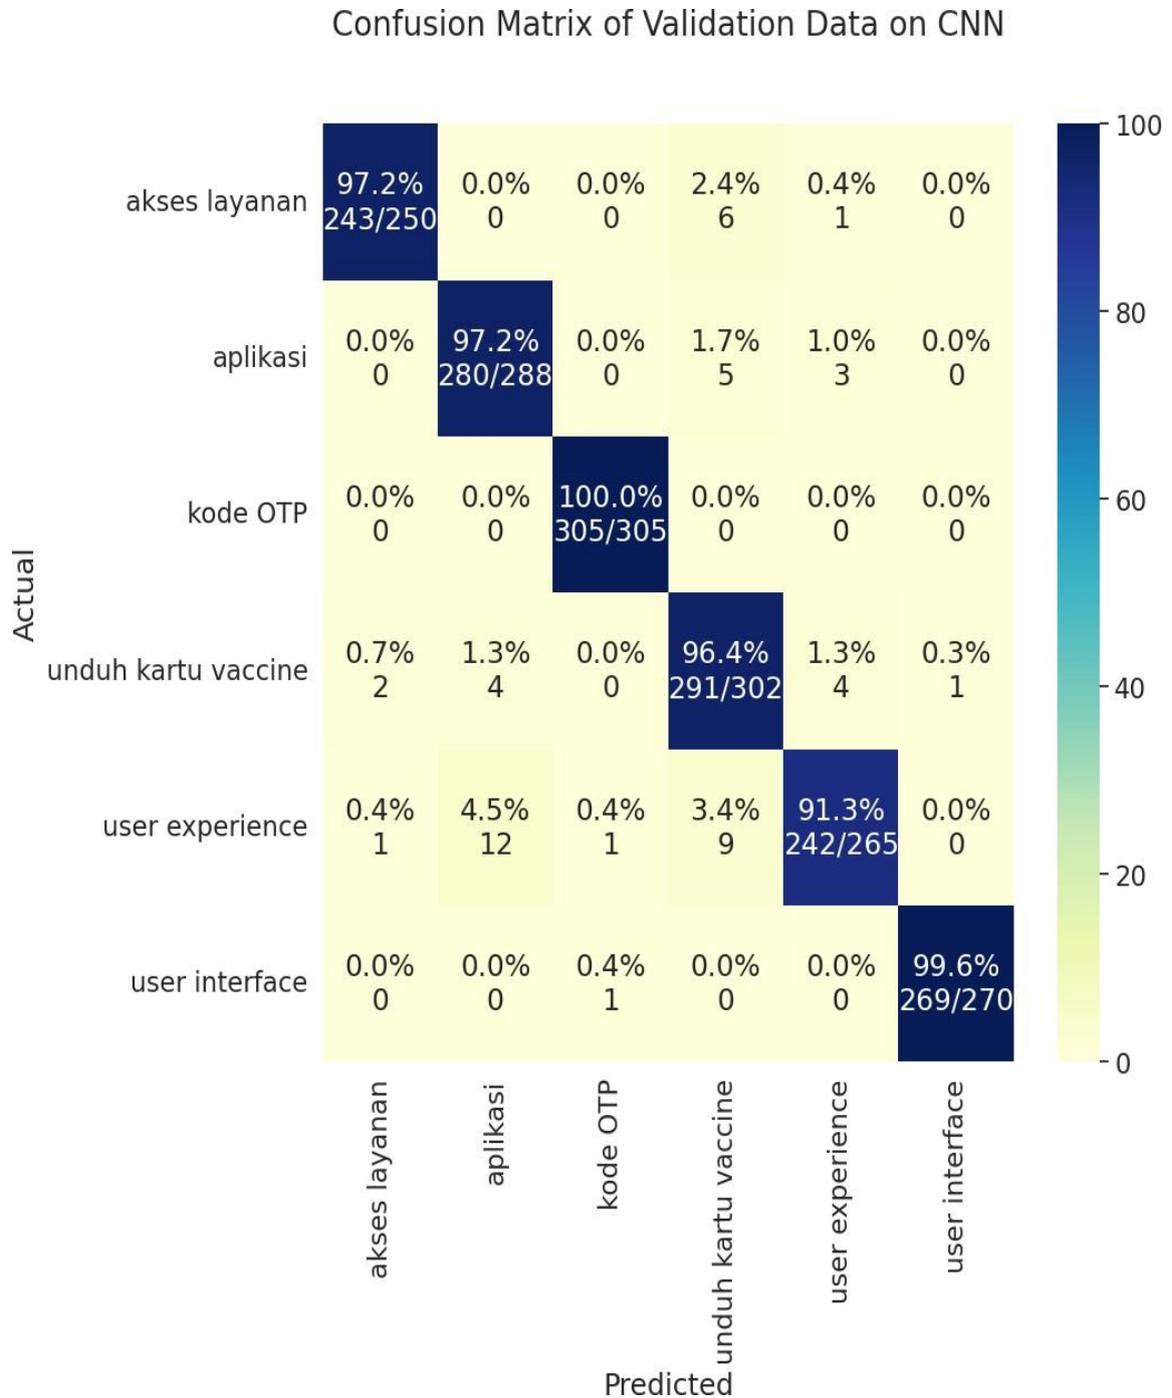
Penelitian ini mengembangkan sebuah model Convolutional Neural Network (CNN) yang terdiri dari sejumlah lapisan. Lapisan pertama berfungsi untuk mengubah kata-kata menjadi vektor berdimensi rendah. Lapisan kedua menjalankan operasi konvolusi dengan menggunakan beberapa ukuran filter yang berbeda. Hasil dari lapisan konvolusi kemudian dijalankan melalui operasi max-pooling untuk menghasilkan vektor fitur panjang. Selanjutnya, lapisan regularisasi dropout diterapkan pada lapisan fully connected sebelum melakukan klasifikasi. Akhirnya, hasil klasifikasi dimasukkan ke dalam lapisan ReLU, dan peneliti juga memasukkan lapisan softmax untuk melakukan klasifikasi aspek, seperti yang terlihat dalam Gambar 4.17. Skrip program untuk model CNN dapat dilihat pada bagian berikut.

Tabel 4.6 Hasil Evaluasi pada Klasifikasi Aspek

Model	Precision	Recall	F1 Score	Accuracy
CNN	0.97	0.97	0.97	0.97
GRU	0.96	0.96	0.96	0.96
TCN	0.93	0.93	0.93	0.93

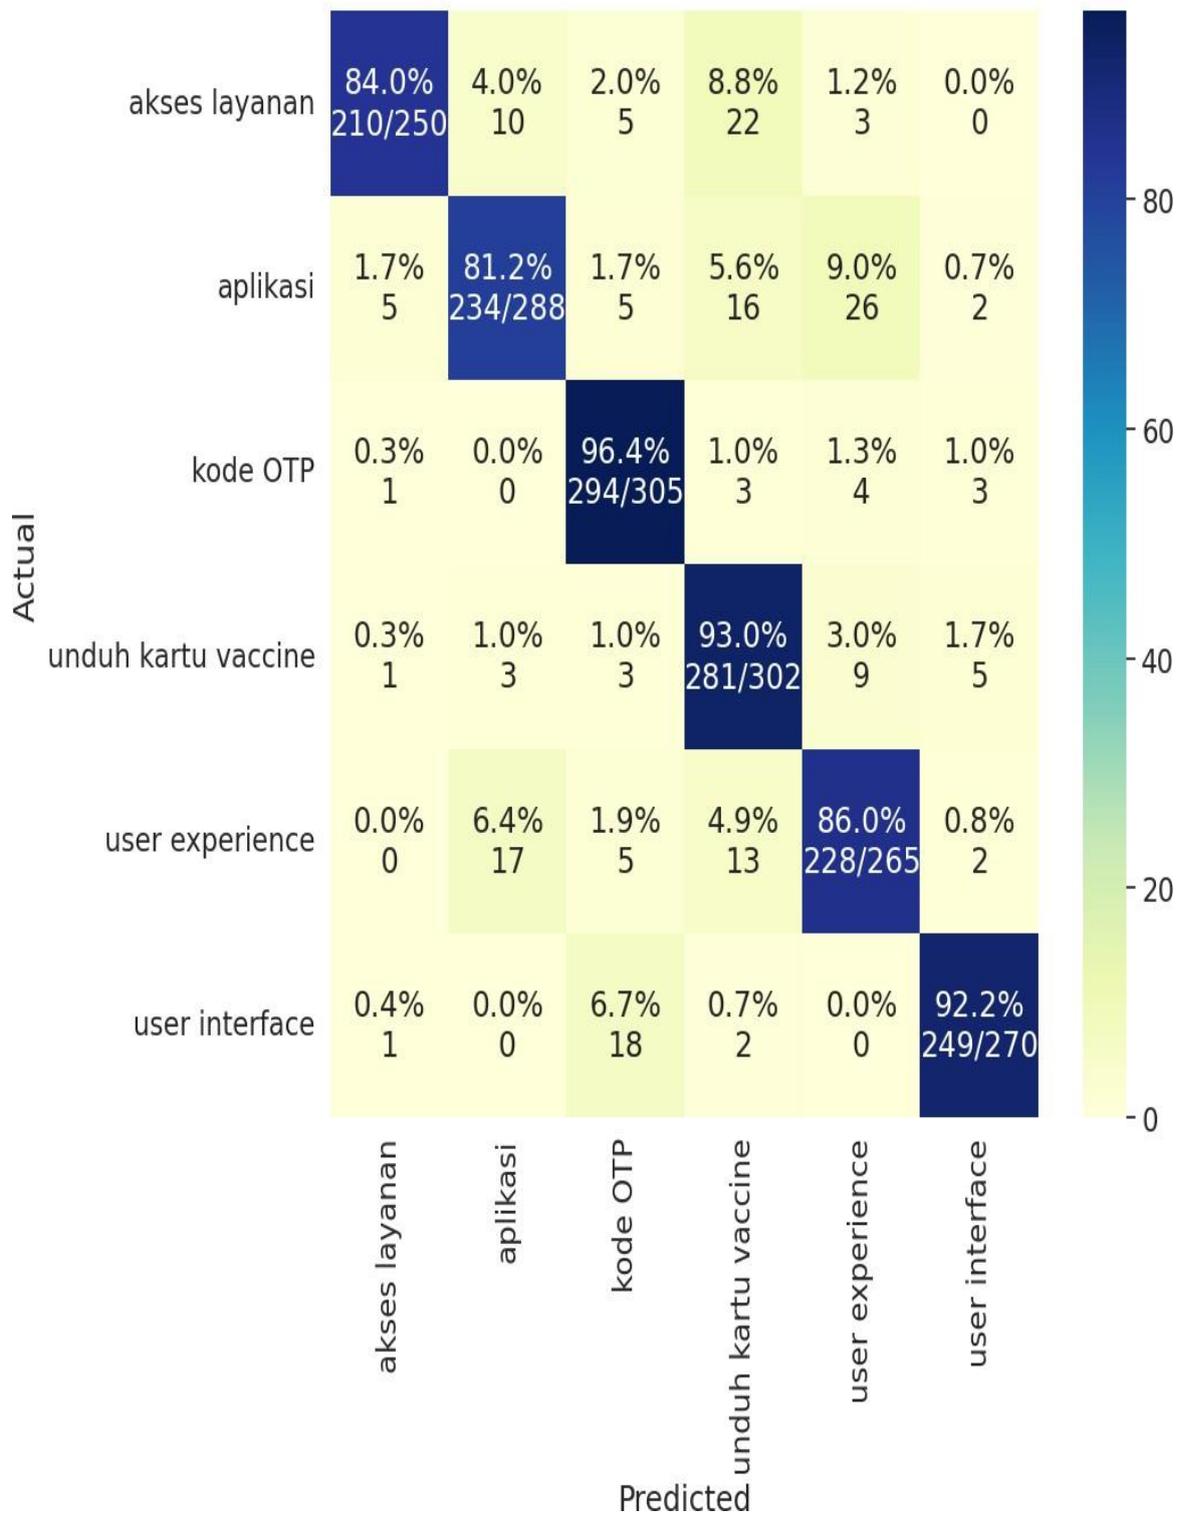
Grafik loss pada klasifikasi aspek menunjukkan nilai sebesar 0.1318 untuk model CNN, sementara model TCN memiliki nilai loss sebesar 0.3217, dan model GRU memiliki loss terakhir dengan nilai 0.1535. Dari ketiga model yang telah dibangun, terlihat bahwa model TCN memiliki loss terbesar, sementara model CNN memiliki loss terkecil. Hasil dari confusion matrix untuk klasifikasi aspek dapat dilihat pada Gambar 4.26 untuk model CNN, Gambar 4.27 untuk model TCN, dan Gambar 4.28 untuk model GRU. Selain itu,

tersedia pula grafik untuk memvisualisasikan perubahan loss dan akurasi selama pelatihan klasifikasi aspek. Gambar 4.29 menunjukkan grafik loss dan akurasi untuk model CNN, Gambar 4.30 untuk model TCN, dan terakhir, Gambar 4.31 untuk model GRU.



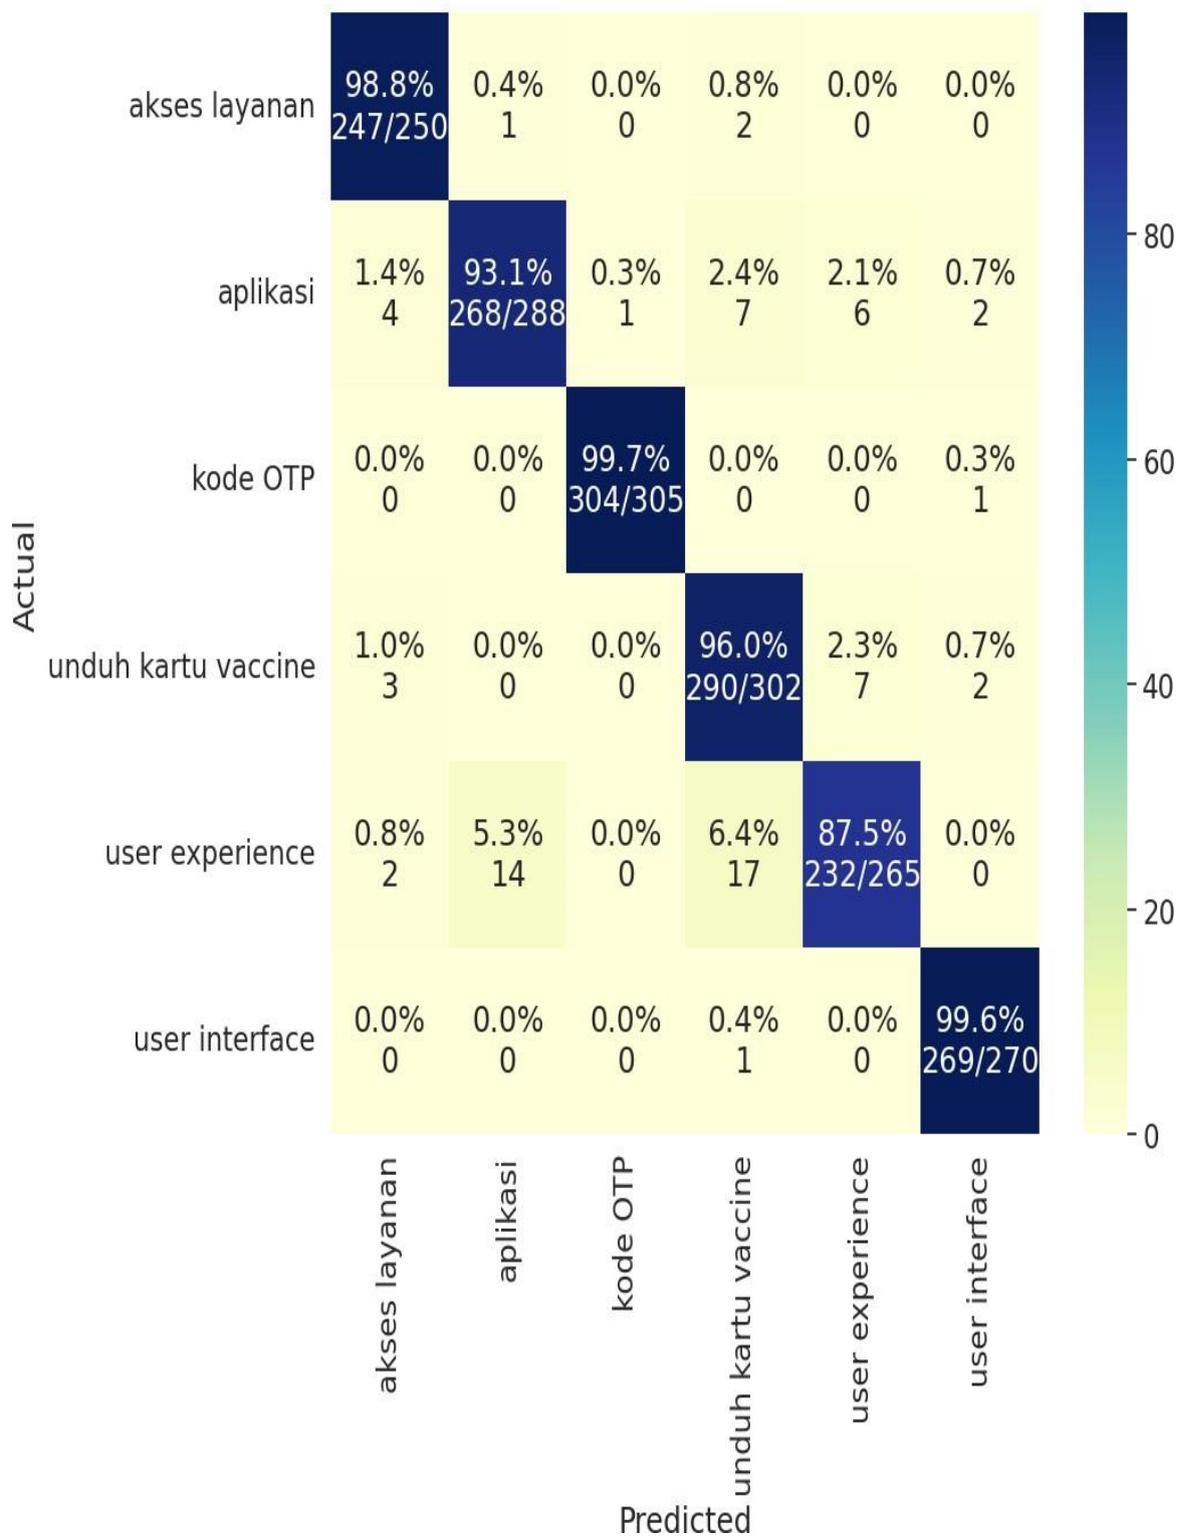
Gambar 4.26 Confusion Matrix Klasifikasi Aspek Model CNN

Confusion Matrix of Validation Data on TCN



Gambar 4.27 Confusion Matrix Klasifikasi Aspek Model TCN

Confusion Matrix of Validation Data on GRU



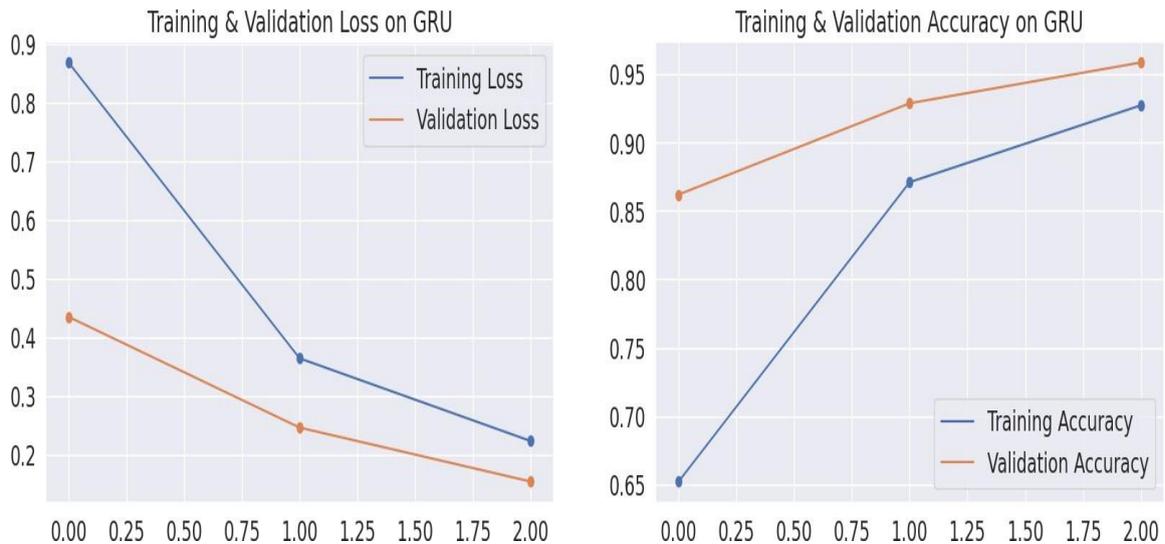
Gambar 4.28 Confusion Matrix Klasifikasi Aspek Model GRU



Gambar 4.29 Grafik Loss dan Accuracy Klasifikasi Aspek Model CNN



Gambar 4.30 Grafik Loss dan Accuracy Klasifikasi Aspek Model TCN



Gambar 4.31 Grafik Loss dan Accuracy Klasifikasi Aspek Model GRU

1.7. Pengujian Model

Pada penelitian ini, tiga model yang diterapkan untuk klasifikasi sentimen dan aspek adalah CNN, TCN, dan GRU. Setelah dilakukan penyetelan hyperparameter dengan menggunakan algoritma Adam, hasil akurasi terbaik diperoleh dari model CNN dalam proses evaluasi. Pemilihan model ini didasarkan pada anggapan bahwa semakin tinggi tingkat akurasi, semakin baik pula performa model. Model CNN berhasil mencapai tingkat akurasi tertinggi, yaitu 0.98 untuk klasifikasi sentimen dan 0.97 untuk klasifikasi aspek. Evaluasi terhadap klasifikasi aspek dapat ditemukan pada Gambar 4.14, di mana setiap aspek mencapai akurasi di atas 0.90%. Hasil akurasi tertinggi dalam klasifikasi aspek ditemukan pada aspek OTP dengan nilai 100.0%, sedangkan akurasi terendah tercatat pada aspek pengalaman pengguna dengan nilai 91.3%. Berdasarkan hasil evaluasi confusion matrix, kesalahan klasifikasi terbesar terjadi pada aspek pengalaman pengguna yang salah diprediksi sebagai aspek aplikasi. Kesalahan ini terjadi karena terdapat kemiripan dalam ulasan antara aspek pengalaman pengguna dan aplikasi, seperti contohnya "sistem eror" dan "kesulitan saat masuk". Langkah terakhir dalam penelitian ini adalah pengujian model. Tiga arsitektur, yaitu CNN, GRU, dan TCN, digunakan dalam pembangunan model ABSA. Berdasarkan hasil evaluasi, model CNN memiliki akurasi tertinggi secara keseluruhan dalam klasifikasi sentimen maupun aspek. Oleh karena itu, model yang digunakan dalam pengujian adalah model CNN. Penggunaan model ini memerlukan pembuatan fungsi klasifikasi, seperti yang dijelaskan dalam Gambar 4.32. Selanjutnya, pengujian dilakukan dengan melakukan prediksi terhadap aspek dan sentimen dalam

ulasan aplikasi "pedulilindungi". Hasil dari pengujian model dapat ditemukan pada Gambar 4.33.

```
cls_sentiment = ["Negative", "Positive"]
cls_aspect    = lab_aspect

sample_sentence_output = X_test_vec[:4]

y_preds_sentiment = model_cnn.predict(sample_sentence_output)
y_preds_aspect    = model_cnn_aspect.predict(sample_sentence_output)

result = pd.DataFrame({
    "Sentence"          : feature[:4],
    "Sentiment Actual"  : y_test_sentiment[:4],
    "Sentiment Predicted" : list(map(lambda x: cls_sentiment[x],
y_preds_sentiment.argmax(axis=1))),
    "Aspect Actual"     : y_test_aspect[:4],
    "Aspect Predicted"  : list(map(lambda x: cls_aspect[x],
y_preds_aspect.argmax(axis=1)))
})
```

Gambar 4.32 Script Program ABSA

```
tolong perintah tetap atur syarat jalan sertifikat vaksin layan syarat jalan
Aspect: akses layanan
Sentiment: NEGATIF

terima kasih layan puas
Aspect: akses layanan
Sentiment: POSITIF

harap baik sistem orang vaksin daftar sertifikat wajib harap diperbaiki data aplikasi kecewa sistem buruk
Aspect: aplikasi
Sentiment: NEGATIF

sistem aplikasi buruk banget
Aspect: aplikasi
Sentiment: NEGATIF
```

Gambar 4.33 Hasil Klasifikasi Sentimen & Aspek

Pada Gambar 4.33, terlihat bahwa hasil dari pengujian model ABSA untuk klasifikasi sentimen dan aspek berhasil menghasilkan label yang konsisten dengan label asli dari data. Fenomena ini dapat dijelaskan oleh jumlah data yang cukup besar yang digunakan dalam pelatihan model. Karena adanya variasi yang kaya dalam kalimat-kalimat yang diproses, algoritma mampu mempelajari dengan baik berbagai pola dan konteks yang terkandung

dalam ulasan-ulasan tersebut. Hal ini membantu model untuk memberikan prediksi yang akurat terhadap sentimen dan aspek yang terdapat dalam ulasan aplikasi. Faktor kualitas dan jumlah data pelatihan memainkan peran penting dalam kesuksesan model dalam mempelajari pola-pola yang ada dalam data. Semakin banyak data dan semakin beragam variasi kalimat yang tercakup dalam data, semakin baik model dapat memahami dan menggeneralisasi ulasan-ulasan baru yang belum pernah dilihat sebelumnya. Penting untuk diingat bahwa kinerja model juga dapat dipengaruhi oleh pemilihan arsitektur yang tepat, metode penyetelan hyperparameter yang cermat, serta pemrosesan data yang benar. Namun, pada tahap ini, hasil yang dicapai pada Gambar 4.33 menunjukkan bahwa model ABSA berhasil dalam tugas klasifikasi sentimen dan aspek, dan kemampuannya dalam memprediksi label dengan akurasi yang sesuai dengan label aslinya.

1.8. Visualisasi dan Interpretasi Data

Visualisasi data menggunakan word cloud digunakan untuk menggambarkan sentimen pada setiap aspek. Word cloud adalah bentuk visualisasi yang mengilustrasikan kata-kata dari teks yang diberikan dengan ukuran font yang lebih besar sesuai dengan frekuensi kemunculannya. Semakin besar ukuran font suatu kata, semakin sering kata tersebut muncul dalam teks. Hasil visualisasi ini memungkinkan kita untuk secara intuitif melihat kata-kata yang paling umum muncul dalam konteks sentimen pada berbagai aspek. Untuk ilustrasi lebih lanjut, gambar dapat ditemukan pada gambar yang disertakan di bawah ini.



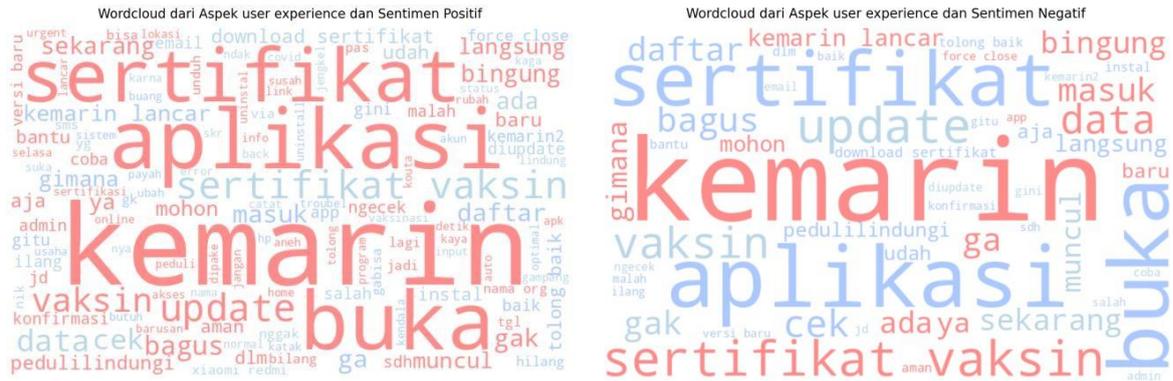
Gambar 4.34 Word cloud Aspek Aplikasi Positif dan Negatif

Berdasarkan pada Gambar 4.34, Word Cloud untuk aspek aplikasi memperlihatkan sentimen positif dan negatif. Sentimen positif pada aspek aplikasi menunjukkan bahwa "pedulilindungi" dapat digunakan untuk mengakses sertifikat vaksin melalui aplikasi tersebut. Namun, terdapat juga sentimen negatif yang mengindikasikan bahwa pengguna merasa bahwa sistem masih memiliki kekurangan dan tidak berfungsi dengan baik dalam mendeteksi daerah yang terpapar COVID-19.



Gambar 4.35 Word cloud Aspek User Interface Positif dan Negatif

Word Cloud pada aspek User Interface menggambarkan sentimen positif dan negatif. Sentimen positif pada aspek User Interface menunjukkan bahwa aplikasi "pedulilindungi" memiliki fitur-fitur yang sangat bermanfaat untuk aktivitas seperti perjalanan, termasuk kemudahan akses sertifikat vaksin tanpa pendaftaran kartu fisik, notifikasi zona risiko, dan paspor digital. Namun, terdapat juga sentimen negatif yang menunjukkan bahwa beberapa pengguna mengalami kesulitan dalam mengoperasikan beberapa fitur yang ada. Sebagai contoh, saat mendaftar kartu vaksin, pengisian tanggal lahir dianggap sebagai proses yang melelahkan. Oleh karena itu, beberapa pengguna menyarankan agar fitur pengisian tanggal lahir perlu diperbaiki untuk meningkatkan kenyamanan pengguna.



Gambar 4.36 Word cloud Aspek User Experience Positif dan Negatif

Word Cloud pada aspek User Interface mencerminkan sentimen positif dan negatif. Sentimen positif pada aspek User Interface menggambarkan bahwa aplikasi 'pedulilindungi' memiliki fitur-fitur yang sangat berharga, terutama untuk aktivitas seperti perjalanan. Ini termasuk kemudahan akses sertifikat vaksin tanpa perlu mendaftarkan kartu fisik, notifikasi mengenai zona risiko, dan adanya paspor digital. Namun, di sisi lain, terdapat juga sentimen negatif yang mengindikasikan bahwa beberapa pengguna mengalami kesulitan dalam menggunakan beberapa fitur aplikasi. Sebagai contoh, dalam proses mendaftarkan kartu vaksin, pengisian tanggal lahir dianggap sebagai tahap yang melelahkan dan kompleks. Oleh karena itu, beberapa pengguna merekomendasikan agar fitur pengisian tanggal lahir ditingkatkan guna meningkatkan kenyamanan pengguna.



Gambar 4.37 Word cloud Aspek Kode OTP Positif dan Negatif

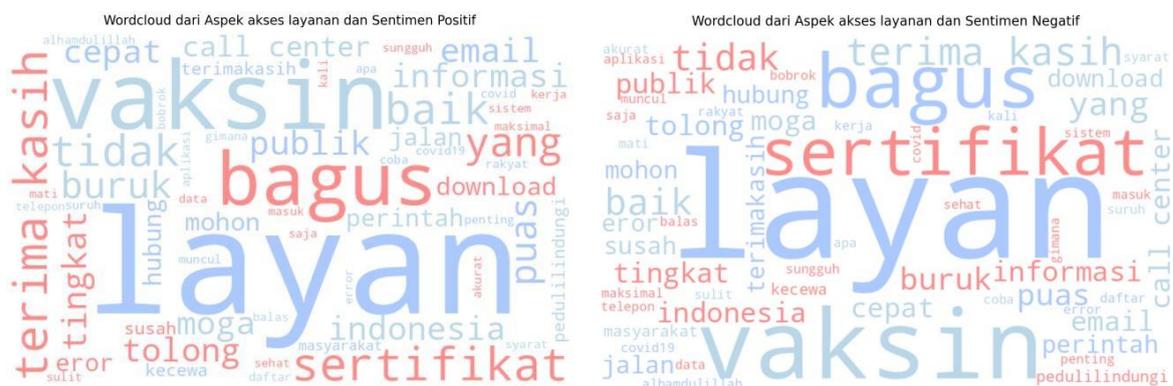
Word Cloud pada aspek Kode OTP, seperti yang terlihat pada Gambar 4.37, menggambarkan sentimen positif dan negatif. Sentimen positif pada aspek Kode OTP menunjukkan bahwa sebagian pengguna mengalami pengiriman kode OTP dengan cepat. Namun, terdapat juga saran agar proses pengiriman kode OTP lebih cepat. Di sisi lain,

dalam konteks sentimen negatif, pengguna merasa terganggu oleh pengiriman kode OTP yang lambat, yang menghambat proses verifikasi. Sehingga, pengalaman ini dianggap sebagai hal yang negatif dan menghambat pengguna dalam melakukan verifikasi dengan lancar.



Gambar 4.38 Word cloud Aspek Kartu Vaksin Positif dan Negatif

Pada Gambar 4.38, Word Cloud pada aspek Kartu Vaksin memperlihatkan sentimen positif dan negatif. Sentimen positif pada aspek Kartu Vaksin menggambarkan bahwa aplikasi "pedulilindungi" memberikan kemudahan dalam mengunduh atau memeriksa sertifikat vaksin tanpa perlu membawa fisik salinan atau mengingat password kesehatan secara manual. Cukup dengan menggunakan aplikasi "pedulilindungi," pengguna dapat mengakses riwayat vaksin secara digital. Namun, dari sisi sentimen negatif, ada pengguna yang mengalami kesulitan saat mencoba mengakses sertifikat menggunakan dua akun berbeda dalam satu perangkat. Hal ini dianggap sebagai kendala negatif dalam penggunaan aplikasi.



Gambar 4.39 Word cloud Aspek Layanan Positif dan Negatif

Pada Gambar 4.39, Word Cloud pada aspek Layanan menunjukkan sentimen positif dan negatif. Sentimen positif pada aspek Layanan mencerminkan bahwa pengguna merasa puas dengan pelayanan yang diberikan, terutama dalam menanggapi keluhan yang mereka laporkan. Namun, dari segi sentimen negatif, ada pengguna yang merasa bahwa layanan yang diberikan masih belum memuaskan, terutama dalam menanggapi keluhan mengenai kesalahan dalam pendataan sertifikat dan akses publik.

Tabel 4.7 Aspek Positif dan Negatif

Aspek	Positif	Negatif
Aplikasi	Bermanfaat Bagus	Sistem Error Buruk Susah
User Interface	Fitur sertifikat Deteksi Zona	Zona tidak akurat Pengisian tanggal lahir melelahkan Fitur eror
User Experience	Lancar sebelum update	Eror setelah update
Kode OTP	Saran pengiriman OTP	OTP Lambat OTP Kadaluarsa
Kartu Vaksin	Sertifikat vaksin digital	Susah akses sertifikat
Akses Layanan Publik	Tanggap keluhan Keseimbangan hak	Layanan tidak bagus

Tabel 4.7 menjelaskan tentang kelebihan dan kekurangan dari setiap aspek yang diamati selama masa penelitian ini. Informasi tersebut diharapkan dapat menjadi evaluasi yang berharga terhadap aplikasi "pedulilindungi." Khususnya, penekanan pada aspek negatif memberikan wawasan berharga untuk meningkatkan pengalaman pengguna dan memastikan bahwa pengguna merasa lebih mudah dalam mengoperasikan aplikasi "pedulilindungi".

BAB 5

Penutup

5.1 Kesimpulan

Data diambil dari Maret 2020 hingga Agustus 2021 dan dilabeli secara manual untuk aspek dan berdasarkan rating pengguna untuk sentimen. Setelah proses labelisasi, terdapat 23.167 ulasan untuk aplikasi "pedulilindungi". Namun, untuk mencegah overfitting, peneliti menerapkan teknik under-sampling dengan mengambil jumlah data terkecil. Hal ini dilakukan untuk menghindari overfitting, sehingga data yang digunakan dalam evaluasi hanya sebanyak 1.400 ulasan di semua aspek. Penelitian ini menggunakan tiga metode, yaitu CNN, TCN, dan GRU. Model CNN menghasilkan akurasi tertinggi dibandingkan dengan dua model lainnya. Nilai akurasinya adalah 0.98 untuk klasifikasi sentimen dan 0.97 untuk klasifikasi aspek. Model CNN memiliki konfigurasi dengan 128 filter, 5 kernel, 100 hidden dimensions, 193 panjang input, dan ukuran batch 16. Berdasarkan hasil penelitian ini, kelebihan aplikasi "pedulilindungi" adalah kemampuan untuk mengunduh sertifikat vaksin dan digunakan sebagai bukti untuk mengakses layanan publik. Namun, ada beberapa kekurangan yang diidentifikasi. Sejumlah pengguna mengalami kesulitan dalam mengakses aplikasi ini karena jumlah pengguna yang tinggi. Masalah lain termasuk informasi yang tidak valid, terutama terkait peran aplikasi dalam pelacakan digital, kesalahan dalam data penerima vaksin, proses penerbitan sertifikat vaksin yang lambat, permintaan login berulang dengan memasukkan NIK, dan kegagalan yang sering terjadi dalam pengiriman OTP.

5.2 Saran

Terdapat beberapa saran bagi peneliti lain yang tertarik untuk melanjutkan penelitian terkait:

1. **Pertimbangkan Model Lain:** Peneliti dapat menjelajahi model machine learning atau deep learning yang berbeda untuk proses klasifikasi. Pilihan model yang beragam dapat memberikan wawasan lebih lanjut tentang kinerja dan kecocokan model pada data yang sama.
2. **Teknik Penanganan Data Tidak Seimbang:** Jika data memiliki ketidakseimbangan kelas yang signifikan, peneliti dapat mengeksplorasi teknik lain untuk menangani masalah ini. Selain teknik under-sampling, teknik oversampling atau metode ensemble dapat dipertimbangkan untuk menghasilkan hasil yang lebih baik.
3. **Pemanfaatan Part-of-Speech (POS) Tagger:** Menggunakan Part-of-Speech (POS) Tagger untuk melabeli kelas kata dapat membantu meningkatkan kualitas labelisasi sentimen. Ini dapat membantu memahami konteks kata dan memberikan informasi lebih lanjut tentang nuansa sentimen yang mungkin sulit dideteksi hanya dari kata itu sendiri.
4. **Tahap Preprocessing yang Lebih Komprehensif:** Menambahkan tahap preprocessing yang lebih komprehensif dapat membantu mengurangi noise dalam data. Ini dapat termasuk pembersihan teks, normalisasi kata, penghapusan tanda baca, dan langkah-langkah lain untuk mempersiapkan data dengan lebih baik sebelum masuk ke tahap klasifikasi.
5. **Semua saran ini dapat membantu peneliti lain dalam mengembangkan dan meningkatkan metodologi yang ada serta dalam mendapatkan wawasan yang lebih dalam dalam penelitian terkait analisis sentimen aplikasi "pedulilindungi" atau dalam bidang yang serupa.**

Daftar Pustaka

- Alqaryouti, O., Siyam, N., Monem, A. A., & Shaalan, K. (2019). Aspect-based sentiment analysis using smart government review data. *Applied Computing and Informatics*. <https://doi.org/10.1016/j.aci.2019.11.003>
- An Naim, F. (2020). *BANGLA ASPECT-BASED SENTIMENT ANALYSIS BY SUPERVISED LEARNING BASED ON ASPECT TERM EXTRACTION*.
- Ari Nasichuddin. (2017). Implementasi CNN untuk Klasifikasi Teks Menggunakan Tensorflow.
- Arianto, D., & Budi, I. (2020). *Aspect-based Sentiment Analysis on Indonesia's Tourism Destinations Based on Google Maps User Code-Mixed Reviews (Study Case: Borobudur and Prambanan Temples)*. <https://maps.google.com/localguides>
- Axhiu, M., & Aliu, A. (2021). SEMI-SUPERVISED ASPECT-BASED SENTIMENT ANALYSIS ON ALBANIAN RESTAURANT REVIEWS. In *KNOWLEDGE-International Journal* (Vol. 45, Issue 3).
- Bai, S., Kolter, J. Z., & Koltun, V. (2018). *An Empirical Evaluation of Generic Convolutional and Recurrent Networks for Sequence Modeling*. <http://arxiv.org/abs/1803.01271>
- Bhargav, J. (2019). *Product Design Improvement System using Aspect Based Sentiment Analysis of Consumer Reviews Learning Interactions and Dynamics of Swarms View project Aspect Based Sentiment Analysis of Consumer Reviews View project*. <https://www.researchgate.net/publication/343726171>.
- D. Ekawati and M. L. Khodra, "Aspect-based sentiment analysis for Indonesian restaurant reviews," (2017). International Conference on Advanced Informatics, Concepts, Theory, and Applications (ICAICTA), 2017, pp. 1-6, doi: 10.1109/ICAICTA.2017.8090963.
- Dhabekar, S., & Patil, M. D. (2021). Implementation of Deep Learning Based Sentiment Classification and Product Aspect Analysis. *ITM Web of Conferences*, 40, 03032. <https://doi.org/10.1051/itmconf/20214003032>.
- Gu, S., Zhang, L., Hou, Y., & Song, Y. (2018). *A Position-aware Bidirectional Attention Network for Aspect-level Sentiment Analysis*.
- Huang, J., Meng, Y., Guo, F., Ji, H., & Han, J. (2020). *Weakly-Supervised Aspect-Based Sentiment Analysis via Joint Aspect-Sentiment Topic Embedding*. <https://github>

- Jonathan Long, Evan Shelhamer., Trevor Darrell (2015). Fully convolutional networks for semantic segmentation.
- KABIR, A. I., KARIM, R., NEWAZ, S., & HOSSAIN, M. I. (2018). The Power of Social Media Analytics: Text Analytics Based on Sentiment Analysis and Word Clouds on R. *Informatica Economica*, 22(1/2018), 25–38. <https://doi.org/10.12948/issn14531305/22.1.2018.03>
- Khaled, S. (2017). *Aspect-Based Sentiment Analysis for Government Smart Applications Customers' Reviews* by OMAR HARB ABDELKARIM ALQARYOUTI A dissertation submitted in fulfilment of the requirements for the degree of *INFORMATICS (KNOWLEDGE AND DATA MANAGEMENT)* at The British University in Dubai.
- Kim, Y. (2014). *Convolutional Neural Networks for Sentence Classification*. <http://arxiv.org/abs/1408.5882>
- Laskari, N. K., & Sanampudi, S. K. (2016). *Aspect Based Sentiment Analysis Survey Deep Learning for NLP and IR View project Extraction of Events, Times from natural language text and mapping of the relations between them View project Aspect Based Sentiment Analysis Survey*. 18(2), 24–28. <https://doi.org/10.9790/0661-18212428>.
- Liu, B. (2012). *Sentiment Analysis and Opinion Mining*. Morgan & Claypool Publishers.
- Maragoudakis, M., Fakotakis, N., Kokkinakis, G. (2016). A Bayesian Model for Shallow Syntactic Parsing of Natural Language Text. (January 2016).
- Martínez-Cámara, Eugenio & Barroso, Nuria & Moya, Antonio & Fernández, José & Romero, Elena & Herrera, Francisco. (2019). Deep Learning Hyper-parameter Tuning for Sentiment Analysis in Twitter based on Evolutionary Algorithms. 255-264. 10.15439/2019F183.
- Mikolov, T., Chen, K., Corrado, G., & Dean, J. (2013). *Efficient Estimation of Word Representations in Vector Space*. <http://arxiv.org/abs/1301.3781>.
- Nobre, G., Justino, A., Tadao, F., Nunes, D., Takabayashi, D., & Küllian, R. (n.d.). *BooViews: Aspect-based Sentiment Analysis on Product Reviews combining SVM and CRF in Portuguese*.
- Nurifan, F., Sarno, R., & Sungkono, K. R. (2019). Aspect based sentiment analysis for restaurant reviews using hybrid ELMo-wikipedia and hybrid expanded opinion
- Omar Harb Abdelkarim Alqoryouti (2017). Aspect-based Sentiment Anlysis for government smart Aplications Customers' reviews.

- M. Pontiki, D. Galanis, H. Zhao Papageorgiou, I. Androutsopoulos, S. Manandhar, M. Al-Smadi, M. Al-Ayyoub, Y. Zhao, B. Qin, O. De Clercq, and V Hoste, "SemEval-2016 task 5: Aspect based sentiment analysis," in Proc. 10th Int. Workshop Semantic Eval., SemEval, San Diego, CA, USA: Association for Computational Linguistics, Jun. 2016, pp. 19-30
- Oni Harnantyo. (2019). Analisis Sentiment Tempat Wisata Di Yogyakarta Menggunakan Metode Recurrent Neural Network Dengan Long Short Term Memory.
- Ray Kursweil <https://resources.experfy.com/ai-ml>
- Prameswari., I Surjandari., & E. Laoh. (2017). Opini Mining From Online reviews in bali Tourist Area. *Proceeding – 2017 3rd Int. Conf. Sci. Inf. Technol. Theory and Appl. IT Educ. Ind. Soc. Big Data Era, ICSITech 2017, vol. 2018-Januari, 226-230*, doi: 10.1109/ICSITech.2017.8257115.
- Prasetyo Wahyu Adi Wianto., & Renny Pradina. (2018). *ANALISIS SENTIMEN MEDIA SOSIAL UNTUK TEKS BERBAHASA INDONESIA MENGGUNAKAN ALGORITMA CNN (CONVOLUTIONAL NEURAL NETWORK) (STUDI KASUS: POLITIK)*. (n.d.).
- Rahma Yustihan, S., & Pandu Adikara, P. (2021). *Analisis Sentimen berbasis Aspek terhadap Data Ulasan Rumah Makan menggunakan Metode Support Vector Machine (SVM)* (Vol. 5, Issue 3). <http://j-ptiik.ub.ac.id>
- Rizki Amalia, P., & Winarko, E. (2021). *Aspect-Based Sentiment Analysis on Indonesian Restaurant Review Using a Combination of Convolutional Neural Network and Contextualized Word Embedding*.
- Risca Naquitasia., & Hatta Fudholi., & Lizda Iswari (2022). Analisis Sentimen Berbasis Aspek pada Wisata Halal dengan Metode Deep Learning. *Jurnal Teknoinfo*. 16. 156. 10.33365/jti.v16i2.1516.
- Sabrah Ailiyya. (2020). *ANALISIS SENTIMEN BERBASIS ASPEK PADA ULASAN APLIKASI TOKOPEDIA MENGGUNAKAN SUPPORT VECTOR MACHINE*. (n.d.).
- Sains, F., & Teknologi, D. (2020). *PROGRAM STUDI MATEMATIKA*.
- Utama, I. P. A. M., Prasetyowati, S. S., & Sibaroni, Y. (2021). Multi-Aspect Sentiment Analysis Hotel Review Using RF, SVM, and Naïve Bayes based Hybrid Classifier. *JURNAL MEDIA INFORMATIKA BUDIDARMA*, 5(2), 630. <https://doi.org/10.30865/mib.v5i2.2959>.

- Yang, C., Zhang, H., Jiang, B., & Li, K. (2019). Aspect-based sentiment analysis with alternating coattention networks. *Information Processing and Management*, 56(3), 463–478. <https://doi.org/10.1016/j.ipm.2018.12.004>.
- U. D. Ami, “Apa Itu Text Mining,” (2018). <https://garudacyber.co.id/artikel/1254-apa-itu-text-mining>.